

10

OPTIMIZACIÓN

**DE REDES INALÁMBRICAS RURALES MEDIANTE
APRENDIZAJE AUTOMÁTICO: MEJORA DE LA
CONECTIVIDAD EN ÁREAS REMOTAS**

OPTIMIZACIÓN

DE REDES INALÁMBRICAS RURALES MEDIANTE APRENDIZAJE AUTOMÁTICO: MEJORA DE LA CONECTIVIDAD EN ÁREAS REMOTAS

OPTIMIZATION OF RURAL WIRELESS NETWORKS THROUGH MACHINE LEARNING: IMPROVING CONNECTIVITY IN REMOTE AREAS

Diana Carolina Decimavilla-Alarcón¹

E-mail: ddecimavilla@istvr.edu.ec

ORCID: <https://orcid.org/0000-0002-0375-0216>

Emilio Fernando Jama-Rodríguez¹

E-mail: ef.jama@istvr.edu.ec

ORCID: <https://orcid.org/0009-0007-2715-9547>

¹ Instituto Superior Tecnológico Vicente Rocafuerte. Ecuador.

Cita sugerida (APA, séptima edición)

Decimavilla-Alarcón, D. C., & Jama-Rodríguez, E. F. (2025). Optimización de redes inalámbricas rurales mediante aprendizaje automático: Mejora de la conectividad en áreas remotas. *Revista Mexicana de Investigación e Intervención Educativa*, 4(2), 99-110.

Fecha de presentación: 12/03/2025

Fecha de aceptación: 21/04/2025

Fecha de publicación: 01/05/2025

RESUMEN

La optimización de redes inalámbricas rurales mediante aprendizaje automático representa un desafío fundamental para reducir la brecha digital en áreas remotas, esta investigación tiene como objetivo analizar las estrategias de optimización basadas en aprendizaje automático para redes inalámbricas rurales mediante una revisión sistemática de la literatura científica reciente, la metodología empleada se fundamenta en un enfoque cualitativo con diseño descriptivo-exploratorio, analizando publicaciones académicas indexadas en IEEE Xplore, Scopus y Web of Science durante 2019-2024, los hallazgos revelan que los algoritmos de aprendizaje federado, redes neuronales y aprendizaje por refuerzo han demostrado efectividad significativa en la gestión dinámica de recursos, predicción de patrones de tráfico y optimización energética en entornos rurales, sin embargo, persisten desafíos en términos de disponibilidad de datos, capacidades computacionales y adaptabilidad a entornos dinámicos. Se concluye que la integración del aprendizaje automático con tecnologías emergentes como 5G, IoT y Edge computing está estableciendo las bases para ecosistemas de conectividad más robustos en áreas rurales, aunque se requiere mayor investigación en el desarrollo de algoritmos específicamente adaptados a las limitaciones características de estos entornos, considerando aspectos cruciales como eficiencia energética, escalabilidad, sostenibilidad y la capacidad de respuesta ante condiciones ambientales adversas típicas de las zonas rurales.

Palabras clave:

Redes inalámbricas rurales, aprendizaje automático, optimización de redes, conectividad rural.

ABSTRACT

The optimization of rural wireless networks through machine learning represents a fundamental challenge in reducing the digital divide in remote areas, this research aims to analyze machine learning-based optimization strategies for rural wireless networks through a systematic review of recent scientific literature, the methodology is based on a qualitative approach with a descriptive-exploratory design, analyzing academic publications indexed in IEEE Xplore, Scopus, and Web of Science during 2019-2024, the findings reveal that federated learning algorithms, neural networks, and reinforcement learning have demonstrated significant effectiveness in dynamic resource management, traffic pattern prediction, and energy optimization in rural environments, however, challenges persist in terms of data availability, computational capabilities, and adaptability to dynamic environments. It is concluded that the integration of machine learning with emerging technologies such as 5G, IoT, and edge computing is establishing the foundations for more robust connectivity ecosystems in rural areas, although further research is required in developing algorithms specifically adapted to the characteristic limitations of these environments, considering crucial aspects such as energy efficiency, scalability, sustainability, and the ability to respond to adverse environmental conditions typical of rural areas.

Keywords:

Rural wireless networks, machine learning, network optimization, rural connectivity.

INTRODUCCIÓN

La revolución digital ha transformado significativamente la forma en que nos comunicamos y accedemos a la información, sin embargo, persiste una notable brecha digital entre las zonas urbanas y rurales que amenaza con exacerbar las desigualdades socioeconómicas existentes, en este contexto, las redes inalámbricas rurales emergen como una infraestructura crítica para proporcionar conectividad en áreas geográficamente dispersas y con baja densidad poblacional, enfrentando desafíos únicos que incluyen limitaciones en recursos, condiciones topográficas adversas y restricciones energéticas (Chaoub et al., 2022; Chaabane et al., 2024), la optimización de estas redes representa un reto tecnológico complejo que requiere soluciones innovadoras y adaptativas para garantizar una conectividad eficiente y sostenible.

En los últimos años, el aprendizaje automático ha emergido como una herramienta prometedora para abordar los desafíos de optimización en redes inalámbricas rurales, esta tecnología, fundamentada en la capacidad de los sistemas para aprender de los datos y mejorar su rendimiento a través de la experiencia, ofrece nuevas posibilidades para la gestión dinámica de recursos, la predicción de patrones de tráfico y la adaptación automática a condiciones cambiantes del entorno (Kumar-Samanta et al., 2022; Chandra-Gangwar & Singh, 2023), la integración del aprendizaje automático en la gestión de redes rurales representa un cambio paradigmático en la forma de abordar los problemas de conectividad en áreas remotas, sin embargo, la implementación efectiva de soluciones basadas en aprendizaje automático en entornos rurales enfrenta múltiples obstáculos, la escasez de datos etiquetados, las limitaciones computacionales de los dispositivos desplegados y la variabilidad de las condiciones ambientales representan desafíos significativos que requieren investigación y desarrollo continuo ((Kulin y otros, 2021; Srivastava, 2023).

Adicionalmente, la heterogeneidad de los dispositivos y la necesidad de garantizar la fiabilidad y transparencia de los algoritmos añaden capas adicionales de complejidad al problema de optimización, la problemática central radica en la necesidad de desarrollar estrategias de optimización efectivas y adaptables para redes inalámbricas rurales que puedan operar de manera eficiente bajo restricciones significativas de recursos, este desafío se magnifica por la creciente demanda de servicios digitales en áreas rurales y la necesidad de garantizar una conectividad confiable y de alta calidad para aplicaciones críticas como telemedicina, educación remota y agricultura inteligente (Ramírez-Arroyo et al., 2024).

La búsqueda de soluciones innovadoras basadas en aprendizaje automático para optimizar estas redes representa un área de investigación crucial para el desarrollo sostenible de las comunidades rurales, en este contexto, el presente estudio se propone realizar un análisis

exhaustivo de las estrategias de optimización basadas en aprendizaje automático para redes inalámbricas rurales, con el objetivo de identificar y caracterizar las soluciones más efectivas para mejorar la conectividad en áreas remotas, esta investigación adquiere particular relevancia en un momento en que la transformación digital se acelera globalmente, y la necesidad de cerrar la brecha digital se vuelve cada vez más apremiante para garantizar un desarrollo socioeconómico equitativo y sostenible.

Las redes inalámbricas rurales son infraestructuras de telecomunicaciones diseñadas para proveer conectividad en áreas geográficamente dispersas, con baja densidad poblacional y a menudo con recursos limitado, su objetivo principal es reducir la brecha digital, facilitando el acceso a información, servicios y oportunidades para comunidades que históricamente han estado marginadas de la conectividad digital (Chaoub et al., 2022; Chaabane et al., 2024), las características que definen estas redes incluyen la amplia cobertura geográfica, la baja densidad de usuarios, las limitaciones en la disponibilidad de infraestructura (como energía y backhaul) y la necesidad de soluciones rentables y sostenibles, la adaptabilidad a diferentes condiciones ambientales y topográficas es también crucial para su funcionamiento eficaz.

Dada la naturaleza especial de estos entornos, la arquitectura de estas redes difiere significativamente de las implementaciones urbanas, donde existen grandes concentraciones de usuarios y densas redes celulares, en entornos rurales, es común encontrar topologías de red menos densas, con enlaces de larga distancia y puntos de acceso distribuidos (Pirinen et al., 2019; Chaoub et al., 2022), se emplean diferentes tecnologías, como enlaces de microondas, satélites, redes de baja potencia y repetidores para extender la cobertura a áreas remotas. La arquitectura puede incluir una combinación de redes terrestres y no terrestres (NTN), con un enfoque en soluciones de backhaul eficientes y económicas (Ramírez-Arroyo et al., 2024), además, las arquitecturas flexibles y las que incorporan nodos de bajo costo y mantenimiento reducido son más adecuadas para estas áreas y en algunos casos, se implementan redes de acceso integrado y backhaul (IAB) para simplificar el despliegue y reducir los costos.

La implementación de estas arquitecturas enfrenta múltiples desafíos específicos en entornos rurales, uno de los principales es la baja rentabilidad de la inversión (RoI), debido a la baja densidad de población y el alto costo de infraestructura (Chaoub et al., 2022; Ramírez-Arroyo et al., 2024), la accesibilidad limitada, debido a terrenos difíciles o condiciones climáticas adversas, dificulta el despliegue y el mantenimiento de la red, la falta de infraestructura básica, como la red eléctrica y el backhaul, también es un problema común (Ramírez-Arroyo et al., 2024), además, la disponibilidad limitada de espectro radioeléctrico, así como la necesidad de una planificación

eficiente y una gestión de recursos adaptada a las necesidades específicas de las zonas rurales representan un desafío constante, la necesidad de soluciones energéticamente eficientes, debido a la dificultad de acceso a fuentes de energía confiables, también es un aspecto importante a considerar (Pirinen et al., 2019; Almurshed et al., 2022; Ryo-Koblitz et al., 2024).

Para enfrentar estos desafíos multifacéticos, se ha desarrollado un ecosistema diverso de tecnologías de conectividad rural, las redes celulares, aunque principalmente diseñadas para áreas urbanas, se extienden en zonas rurales, con un enfoque en la optimización de la cobertura y la eficiencia de costos (Ramírez-Arroyo et al., 2024), las redes satelitales también juegan un rol importante, especialmente en áreas extremadamente remotas, ofreciendo conectividad a través de satélites de órbita baja (LEO) o geoestacionarios (GEO) (Chaoub et al., 2022). Los enlaces de microondas se emplean para proporcionar backhaul de larga distancia, conectando nodos de acceso a la red troncal (Pirinen et al., 2019), paralelamente, se utilizan redes de baja potencia y largo alcance (LPWAN) como LoRaWAN y Sigfox, particularmente para aplicaciones de IoT en entornos rurales (Almurshed et al., 2022).

En este contexto tecnológicamente complejo, el aprendizaje automático emerge como una herramienta fundamental para optimizar estas redes, en su esencia, es un campo de la inteligencia artificial que permite a los sistemas aprender de los datos, identificar patrones y tomar decisiones o hacer predicciones sin ser explícitamente programados (Kumar-Samanta et al., 2022; Chandra-Gangwar & Singh, 2023), a diferencia de los sistemas tradicionales basados en reglas, los algoritmos de ML evolucionan y mejoran su rendimiento a través de la experiencia, ajustando sus parámetros internos en función de los datos procesados (Chandra-Gangwar & Singh, 2023).

Este enfoque de aprendizaje se materializa en tres categorías principales: aprendizaje supervisado, aprendizaje no supervisado, y aprendizaje por refuerzo (Kulin et al., 2021). El aprendizaje supervisado opera con datos etiquetados, permitiendo al algoritmo aprender a predecir resultados para nuevas entradas, en contraste, el aprendizaje no supervisado trabaja con datos sin etiquetar, centrándose en descubrir patrones y estructuras inherentes, como el agrupamiento o la reducción de la dimensionalidad (Kumar-Samanta et al., 2022), por su parte, el aprendizaje por refuerzo introduce un paradigma diferente, donde los agentes aprenden a tomar decisiones mediante la interacción con un entorno, recibiendo recompensas o castigos por sus acciones y ajustando su comportamiento en consecuencia (Zhou et al., 2023).

En el contexto específico de las redes inalámbricas rurales, diversos algoritmos han demostrado particular efectividad. La regresión lineal y logística establecen las bases para modelar relaciones entre variables y abordar problemas de clasificación, respectivamente (Kulin et al.,

2021), los árboles de decisión y bosques aleatorios son métodos de clasificación no lineal que son efectivos en tareas de detección y predicción, siendo también útiles en problemas de control de tráfico y asignación de recursos (Kulin et al., 2021), la complejidad de las redes rurales también ha impulsado la adopción de algoritmos de clustering, como k-means, son usados para descubrir estructuras en datos sin etiquetar, lo que permite segmentar usuarios o detectar anomalías en redes (Kumar-Samanta et al., 2022).

En la vanguardia de estas soluciones, las redes neuronales artificiales (ANN), particularmente las redes neuronales convolucionales (CNN) y las redes neuronales recurrentes (RNN), son empleadas para abordar problemas más complejos, como el reconocimiento de patrones, la predicción de tráfico y la optimización de recursos (Kulin et al., 2021), asimismo, las máquinas de vectores de soporte (SVM) son relevantes para clasificación y regresión, especialmente en casos donde los datos no son linealmente separables.

La implementación exitosa de estos algoritmos requiere un proceso meticuloso de entrenamiento y validación. Este ciclo comienza con la recopilación y preparación de datos, donde se aseguran que los datos sean relevantes y estén en formato adecuado para el entrenamiento (Ojo et al., 2022), luego, se selecciona y se entrena un modelo utilizando un subconjunto de los datos disponibles, con el objetivo de optimizar los parámetros para las tareas específicas de la red rural (Kulin et al., 2021), durante esta fase, el modelo desarrolla gradualmente su capacidad para identificar patrones y establecer relaciones significativas en los datos, empleando algoritmos de optimización específicamente adaptados al contexto rural, el proceso culmina con una rigurosa fase de validación, donde se evalúa el desempeño del modelo utilizando datos independientes, verificando su capacidad para generalizar a nuevos escenarios y condiciones de red, esta evaluación se fundamenta en métricas específicas que miden no solo la precisión y eficiencia del modelo, sino también su robustez y adaptabilidad a las condiciones particulares de las redes rurales (Naser & Alavi, 2021).

La optimización de redes busca maximizar la eficiencia y el rendimiento de una red, asegurando que los recursos disponibles se utilicen de la manera más efectiva posible (Zhou et al., 2023) esto implica balancear objetivos a menudo contrapuestos, como aumentar el throughput, minimizar la latencia, reducir el consumo de energía y garantizar la calidad del servicio (QoS) para todos los usuarios (Dreifuerst et al., 2021), los métodos de optimización buscan adaptar dinámicamente la red a las condiciones cambiantes del entorno, como la carga de tráfico, las interferencias y las necesidades de los usuarios, en esencia, la optimización de redes se enfoca en encontrar la mejor configuración posible de los parámetros de la red para lograr los objetivos deseados, mediante la aplicación

de algoritmos y técnicas de gestión de recursos. El objetivo es lograr una red que sea eficiente, robusta, escalable y que se adapte a las necesidades cambiantes (Ryo-Koblitz et al., 2024; Chaabane et al., 2024).

En este contexto de optimización, varios parámetros clave son susceptibles de ajuste mediante técnicas de aprendizaje automático, la potencia de transmisión, la orientación de las antenas (downtilt), la asignación de espectro, la modulación y codificación, y los esquemas de enrutamiento constituyen variables fundamentales que influyen directamente en el rendimiento de la red (Dreifuerst et al., 2021; Zhou et al., 2023), un aspecto particularmente crítico en entornos rurales es la gestión de la interferencia, donde los algoritmos de ML pueden ajustar dinámicamente la potencia y la asignación de canales para minimizar las interferencias entre celdas y usuarios (Kulin et al., 2021), adicionalmente, las tecnologías emergentes como las superficies inteligentes reconfigurables (RIS) introducen nuevas dimensiones de optimización, permitiendo ajustes precisos en los cambios de fase para mejorar la calidad de la señal.

También se consideran la planificación de la ubicación de torres y estaciones base en zonas rurales (Chaabane et al., 2024) y las estrategias de control de la energía para dispositivos móviles, la selección de enlaces en la red y la gestión de colas de tráfico (Kumar-Samanta et al., 2022; Zhang et al., 2022; Mikola et al., 2023; Shi et al., 2023), la optimización de estos parámetros puede lograr mejoras significativas en la capacidad, cobertura y eficiencia energética de la red.

Los métodos de optimización basados en ML han demostrado una capacidad excepcional para manejar la complejidad inherente a las redes rurales, procesando grandes volúmenes de datos y encontrando soluciones óptimas en entornos dinámicos (Wang et al., 2020; Shi et al., 2023), el aprendizaje supervisado permite predecir el rendimiento de la red y tomar decisiones informadas sobre la configuración óptima, mientras que el aprendizaje por refuerzo (RL) se utiliza para que los agentes aprendan a tomar decisiones mediante la interacción con el entorno de la red, ajustando las estrategias de gestión de recursos para maximizar la recompensa (Wang et al., 2020; Dreifuerst et al., 2021; Kumar-Samanta et al., 2022; Zhou et al., 2023). Paralelamente, el aprendizaje no supervisado, como el clustering, se emplean para descubrir patrones en datos de redes y segmentar usuarios (Mikola et al., 2023).

La evolución de las redes rurales está siendo impulsada significativamente por la implementación de tecnología 5G, que representa un salto cualitativo en las capacidades de conectividad. Mientras que las generaciones anteriores de redes móviles se han enfocado principalmente en áreas urbanas densamente pobladas, el 5G ofrece potencial para proporcionar conectividad de banda ancha en regiones remotas (Chaoub et al., 2022), las

características clave de 5G, como mayor capacidad, menor latencia y la capacidad para soportar una gran cantidad de dispositivos, son esenciales para habilitar una variedad de aplicaciones en entornos rurales, como la agricultura de precisión, la monitorización de ganado y la gestión forestal (Ramírez-Arroyo et al., 2024), sin embargo, la implementación de 5G en estas áreas enfrenta desafíos específicos, como los altos costos de despliegue, la baja densidad de usuarios y la falta de infraestructura existente, requiriendo soluciones innovadoras y adaptadas para superar estos obstáculos, se están explorando tecnologías como las redes no terrestres (NTN) y backhaul inalámbrico.

En paralelo, el Internet de las Cosas (IoT) está emergiendo como un catalizador fundamental para la transformación digital rural, permitiendo la conectividad de dispositivos y sensores para monitorear y gestionar diversos aspectos del entorno (Kulin et al., 2021). En la agricultura de precisión, los sensores IoT pueden medir la humedad del suelo, la temperatura, y otros parámetros ambientales, permitiendo optimizar el riego, la fertilización y el uso de pesticidas, lo que mejora la productividad y reduce el impacto ambiental. En la ganadería, el IoT facilita el seguimiento de animales, la monitorización de su salud y la gestión de pastizales, lo que aumenta la eficiencia y el bienestar animal (Ramírez-Arroyo et al., 2024). Además, los dispositivos IoT pueden emplearse para el monitoreo ambiental, la detección temprana de plagas y la gestión de recursos hídricos, creando un ciclo virtuoso de mejora continua en la gestión de recursos rurales.

El edge computing emerge como una solución crucial para abordar los desafíos de latencia y ancho de banda en entornos rurales, acercando la capacidad de procesamiento a la fuente de los datos para la comunicación con la nube (Pirinen et al., 2019; Almurshed et al., 2022), en entornos rurales, donde la conectividad a la nube puede ser limitada, se presenta como una solución esencial para procesar datos localmente y habilitar aplicaciones de tiempo real, por ejemplo, en agricultura de precisión, el edge computing permite procesar datos de sensores en el campo y realizar ajustes inmediatos, o el uso de robots agrícolas que toman decisiones en tiempo real, además, facilita el procesamiento de imágenes y videos para la detección de malas hierbas, el monitoreo de ganado y la gestión forestal, en conjunto, reduce la dependencia de la conectividad a la nube, lo que mejora la robustez y la eficiencia de las aplicaciones en zonas rurales.

Las redes satelitales modernas, particularmente las constelaciones de baja órbita terrestre (LEO), ofrecen una solución viable para proporcionar cobertura en áreas remotas y rurales donde la infraestructura terrestre es limitada o inexistente (Chaoub et al., 2022; Ramírez-Arroyo et al., 2024), estas tecnologías pueden ofrecer conectividad de banda ancha y servir como backhaul para redes terrestres. Las constelaciones LEO permiten superar la

limitación de las redes terrestres en términos de cobertura y alcance, haciéndolas ideales para zonas rurales con terrenos difíciles o dispersos, la integración de redes satelitales con redes terrestres 5G puede dar lugar a soluciones de multi-conectividad, lo que mejora la disponibilidad y fiabilidad de las comunicaciones, cumpliendo con las exigencias de diversas aplicaciones rurales. Sin embargo, es importante considerar los desafíos asociados a las redes satelitales, como la latencia, la gestión de constelaciones y el desecho de satélites al final de su vida útil.

METODOLOGÍA

Esta investigación adopta un enfoque cualitativo con un diseño descriptivo-exploratorio, fundamentado en una exhaustiva revisión sistemática de la literatura científica sobre la optimización de redes inalámbricas rurales mediante aprendizaje automático. La metodología empleada se basa en la recopilación, análisis e interpretación de publicaciones académicas recientes, incluyendo artículos científicos, conferencias y documentos técnicos indexados en bases de datos reconocidas como IEEE Xplore, Scopus y Web of Science durante el período 2019-2024.

El proceso metodológico se estructuró en tres fases principales: identificación, selección y análisis. En la fase de identificación, se realizó una búsqueda sistemática utilizando palabras clave específicas relacionadas con redes inalámbricas rurales, aprendizaje automático y optimización de redes. La fase de selección implicó la aplicación de criterios de inclusión y exclusión para filtrar los documentos más relevantes, considerando factores como el año de publicación, la pertinencia temática y el rigor metodológico. La fase de análisis comprendió una revisión detallada de los documentos seleccionados, categorizando la información según las dimensiones clave del estudio: algoritmos de ML, tendencias tecnológicas y desafíos de implementación.

El análisis de los documentos se realizó mediante un enfoque interpretativo, identificando patrones, tendencias y relaciones significativas entre los diferentes aspectos de la optimización de redes rurales mediante ML. Este proceso permitió sintetizar el conocimiento existente y generar una comprensión profunda de las estrategias de optimización más efectivas, así como de los desafíos y oportunidades en este campo. La metodología adoptada facilitó la construcción de un marco conceptual sólido que integra las diversas perspectivas y avances en la aplicación de ML para mejorar la conectividad en áreas remotas.

DESARROLLO

Los resultados de esta investigación presentan un análisis exhaustivo sobre la aplicación del aprendizaje automático en la optimización de redes inalámbricas rurales, basado en una revisión sistemática de la literatura científica reciente, el análisis aborda las diferentes dimensiones

de esta integración tecnológica, desde la caracterización de algoritmos hasta la identificación de tendencias y desafíos emergentes.

La implementación de algoritmos de aprendizaje automático (ML) en redes rurales se encuentra en una fase inicial, pero con un creciente interés debido a su potencial para optimizar el rendimiento y superar las limitaciones de infraestructura, las investigaciones y proyectos piloto actuales exploran diversas aplicaciones, como la gestión inteligente de recursos, la optimización de la asignación de espectro y la mejora de la eficiencia energética en estas redes (Wang et al., 2020), sin embargo, la escasez de datos etiquetados y la limitada capacidad computacional en entornos rurales son barreras significativas para la adopción generalizada de ML, para abordar estos desafíos, se están implementando técnicas como el aprendizaje federado (FL) y el edge computing está facilitando la implementación de ML en estas zonas, permitiendo el entrenamiento de modelos de forma descentralizada (Almurshed et al., 2022; Shi et al., 2023; Zhou et al., 2023; Lü, 2024). Además, se están adaptando algoritmos existentes para que sean más eficientes en entornos con pocos recursos (Srivastava, 2023).

En este contexto de evolución tecnológica, la selección del algoritmo de ML más adecuado depende fundamentalmente del problema específico a resolver y de las características particulares de cada red rural. Los algoritmos de regresión son útiles para predecir valores numéricos, como la calidad del enlace, la demanda de tráfico o la pérdida de señal, específicamente, la regresión lineal, no lineal y logística, junto con los árboles de decisión, random forests y máquinas de vectores de soporte (SVM) se utilizan para este propósito (Kulin et al., 2021; Chandra-Gangwar & Singh, 2023), estos algoritmos se entrenan con datos etiquetados, aprendiendo la relación entre las variables de entrada y salida. Por ejemplo, se puede usar regresión para predecir la intensidad de la señal basándose en datos de ubicación y condiciones ambientales, optimizando así la gestión de la red (Ojo et al., 2022).

Complementando estos enfoques de regresión, los algoritmos de clasificación juegan un papel fundamental en la categorización de datos de red, especialmente en tareas críticas como la detección de intrusiones, la clasificación del tipo de tráfico o la identificación de usuarios, algoritmos como k-NN, redes neuronales y SVM son útiles para esta tarea (Kulin et al., 2021; Kumar-Samanta et al., 2022; Chandra-Gangwar & Singh, 2023), su capacidad para segmentar usuarios o detectar anomalías en el comportamiento de la red contribuye significativamente a la seguridad y gestión eficientes de las infraestructuras rurales (Wang et al., 2020; Almurshed et al., 2022; Kumar-Samanta et al., 2022).

En el ámbito del aprendizaje no supervisado, los algoritmos de clustering han emergido como herramientas valiosas para descubrir patrones ocultos en datos no

etiquetados facilitando el descubrimiento de patrones ocultos y la segmentación de la red. El algoritmo k-means, en particular, ha demostrado ser útil para agrupar usuarios con patrones de tráfico similares, o para identificar áreas con problemas de conectividad recurrentes (Kulin et al., 2021; Chandra-Gangwar & Singh, 2023), esta capacidad para analizar datos sin etiquetar resulta especialmente relevante en entornos rurales, donde la información etiquetada suele ser escasa o costosa de obtener.

Un avance significativo en la optimización de redes rurales se ha logrado mediante algoritmos de aprendizaje por refuerzo (RL), que permiten a los agentes aprender y tomar decisiones óptimas a través de la interacción continua con el entorno de red. Esta tecnología ha demostrado ser particularmente efectiva en la gestión dinámica de recursos, la optimización del enrutamiento y el control de potencia en entornos complejos (Wang et al., 2020; Zhou et al., 2023), la implementación de algoritmos específicos como DQN y DDPG ha permitido optimizar las políticas de control en la red, adaptándolas continuamente a las condiciones cambiantes del entorno rural, el RL permite que la red aprenda a optimizar su rendimiento con el tiempo, mejorando su adaptación y eficiencia (Zhang et al., 2022).

La evaluación de casos de éxito en la implementación de estas tecnologías ha revelado resultados prometedores en múltiples áreas, se han documentado mejoras significativas en la optimización de rutas, la asignación de recursos y la gestión energética en redes rurales (Almurshed et al., 2022; Wang et al., 2020; Kumar-Samanta et al., 2022; Mikola et al., 2023), particularmente notable ha sido el éxito del uso de FL para el entrenamiento de modelos en dispositivos locales, superando las limitaciones de la conectividad a la nube y protegiendo la privacidad de los datos (Zhou et al., 2023; Shi et al., 2023), además, algoritmos de regresión y clasificación han mejorado la precisión en la predicción de la calidad del enlace y la detección de anomalías (Ojo et al., 2022).

Las principales limitaciones incluyen la escasez de datos etiquetados, la heterogeneidad de los dispositivos, la variabilidad del entorno y la limitada capacidad computacional de los dispositivos en zonas rurales (Kulin et al., 2021; Srivastava, 2023), la falta de experiencia técnica en ML en estas regiones también dificulta la adopción generalizada, la complejidad de los algoritmos de ML y la necesidad de ajuste de hiperparámetros pueden hacer que su implementación sea desafiante en entornos con recursos limitados (Zhang et al., 2022; Shi et al., 2023). La necesidad de garantizar la fiabilidad y la transparencia de los algoritmos también es una limitación importante.

La escalabilidad de los algoritmos de aprendizaje automático constituye un factor crítico para su implementación efectiva en redes rurales de gran escala, en este contexto, los algoritmos distribuidos y federados han demostrado una capacidad superior de escalabilidad en

comparación con las aproximaciones centralizadas, ya que permiten el procesamiento de datos en múltiples nodos de manera simultánea, reduciendo así la carga computacional en puntos únicos (Kulin et al., 2021; Zhou et al., 2023; Shi et al., 2023), de manera complementaria, los algoritmos basados en grafos han exhibido propiedades destacables de escalabilidad, principalmente debido a su capacidad inherente para representar y procesar eficientemente la estructura topológica de la red, permitiendo una mejor adaptación al crecimiento del sistema (Mikola et al., 2023; Lü, 2024).

Paralelamente, la capacidad de adaptación de los algoritmos a entornos dinámicos emerge como un requisito fundamental en el contexto de las redes rurales, donde factores como la demanda de tráfico, las condiciones ambientales y la disponibilidad de recursos experimentan fluctuaciones significativas. En este sentido, los algoritmos de aprendizaje por refuerzo y los modelos que incorporan técnicas de aprendizaje por transferencia han demostrado una notable capacidad de adaptación frente a las variaciones en las condiciones de la red (Zhang et al., 2022; Shi et al., 2023; Zhou et al., 2023), es particularmente relevante destacar que la habilidad de estos algoritmos para generalizar y adaptarse a nuevos escenarios sin requerir un reentrenamiento completo resulta crucial en el contexto de redes caracterizadas por su naturaleza dinámica y heterogénea (Shi et al., 2023).

La aplicación del aprendizaje automático en redes rurales ha experimentado una notable evolución temporal, transitando desde una idea emergente hasta convertirse en una herramienta fundamental para la optimización y gestión de estas infraestructuras. Inicialmente, las técnicas de ML se limitaban a tareas básicas de clasificación y predicción de tráfico, con un enfoque relativamente simple en la gestión de recursos (Kumar-Samanta et al., 2022). Sin embargo, el desarrollo tecnológico ha impulsado la adopción de algoritmos más sofisticados, como el aprendizaje por refuerzo y las redes neuronales profundas, que permiten abordar desafíos más complejos relacionados con la asignación de recursos y la optimización del rendimiento en tiempo real (Shi et al., 2023). Actualmente, se observa una tendencia hacia la personalización y la adaptabilidad de los modelos ML, lo que permite una gestión más eficiente de las redes rurales en diversas condiciones.

En consonancia con esta evolución, el desarrollo de hardware especializado, particularmente las GPUs y TPUs, ha facilitado significativamente el entrenamiento e implementación de modelos de ML cada vez más complejos en dispositivos móviles y en el borde de la red. Este avance ha sido complementado por la maduración de plataformas de software como TensorFlow y PyTorch, que han simplificado considerablemente el proceso de creación e implementación de algoritmos de ML en entornos rurales (Kumar-Samanta et al., 2022; Shi et al., 2023).

La integración de diferentes tecnologías emerge como una tendencia fundamental en la mejora de la conectividad rural. En este contexto, la convergencia entre redes 5G y dispositivos IoT está habilitando nuevas aplicaciones en sectores críticos como la agricultura de precisión y la monitorización de ganado (Ramírez-Arroyo et al., 2024), esta integración requiere el desarrollo de modelos de ML específicamente diseñados para gestionar grandes volúmenes de datos generados por dispositivos IoT y facilitar aplicaciones que demandan baja latencia (Wang et al., 2020; Shi et al., 2023).

De manera complementaria, el edge computing se está consolidando como una solución crucial para reducir la latencia y optimizar el consumo de ancho de banda, mediante la relocalización del procesamiento de datos más cerca de su fuente (Almurshed et al., 2022), esta tendencia se ve fortalecida por la implementación de técnicas de aprendizaje federado, que permiten el entrenamiento de modelos ML sin necesidad de centralizar los datos, preservando así la privacidad del usuario, un aspecto particularmente relevante en entornos rurales donde la protección de datos es una preocupación primordial (Almurshed et al., 2022; Shi et al., 2023).

La sostenibilidad emerge como un factor determinante en la implementación de soluciones de conectividad rural. Las soluciones basadas en ML están demostrando su capacidad para optimizar el consumo energético mediante la gestión inteligente de recursos y el control dinámico de equipos, esta optimización se logra a través de múltiples capas de la arquitectura RAN, desde el procesamiento en la capa física hasta el control de recursos de radio a escala de red, complementada por investigaciones en inferencia bayesiana para la optimización del consumo energético (Ryo-Koblitz et al., 2024).

En el ámbito del diseño de infraestructura, la selección de materiales sostenibles y el desarrollo de equipos con mayor vida útil están contribuyendo significativamente a la reducción del impacto ambiental. Innovaciones como las antenas reconfigurables basadas en metamateriales demuestran un potencial considerable para mejorar la eficiencia y reducir el consumo de recursos (Chaoub et al., 2022), este enfoque en la sostenibilidad se complementa con la exploración de modelos de economía circular para la gestión de residuos y la reutilización de equipos, respaldado por el desarrollo de marcos regulatorios que promueven prácticas sostenibles en la operación de redes.

La implementación de soluciones de ML en redes rurales enfrenta limitaciones significativas que requieren atención prioritaria. Una de las restricciones más críticas es la disponibilidad y calidad de los datos necesarios para el entrenamiento de modelos ML, particularmente en áreas rurales donde la recopilación de datos puede ser limitada y costosa (Kulin et al., 2021; Kumar-Samanta et al., 2022; Shi et al., 2023), los datos disponibles frecuentemente presentan problemas de inconsistencia, errores o

formateo inadecuado, lo que complica significativamente el proceso de entrenamiento y validación de modelos (Srivastava, 2023). Adicionalmente, la complejidad computacional inherente a ciertos algoritmos de ML, especialmente las redes neuronales profundas, representa un obstáculo considerable para su implementación en dispositivos con recursos limitados, el proceso de entrenamiento de estos modelos puede resultar computacionalmente costoso y demandar tiempos significativos, lo que plantea desafíos particulares en entornos rurales donde los recursos computacionales son escasos, esta limitación se ve exacerbada por los requisitos energéticos asociados al uso de ML en dispositivos móviles, un factor crítico en entornos donde las fuentes de energía son limitadas o poco confiables.

La generalización de modelos emerge como otro desafío fundamental, ya que los modelos entrenados en entornos específicos pueden mostrar dificultades para adaptarse efectivamente a otras áreas rurales con características diferentes, los sesgos presentes en los datos de entrenamiento pueden no reflejar adecuadamente las condiciones reales en zonas rurales, limitando la aplicabilidad y efectividad de los modelos (Srivastava, 2023), esta problemática se ve amplificada por la capacidad limitada de los modelos para adaptarse rápidamente a cambios repentinos en el tráfico o la topología de la red, lo que puede comprometer su eficacia operativa (Mikola et al., 2023). Es decir, los cambios en el entorno de la red pueden hacer que los modelos entrenados previamente pierdan eficacia. Por otro lado, el uso de ML en dispositivos móviles puede aumentar el consumo de energía, lo que es una limitación en entornos con fuentes de energía limitadas (Kulin y otros, 2021), además, la falta de conjuntos de datos y métricas de evaluación estandarizados dificulta la comparación entre diferentes enfoques de ML (Kulin et al., 2021).

Frente a estas limitaciones, surgen diversas brechas de investigación que requieren atención urgente, en el ámbito técnico, existe una necesidad apremiante de desarrollar algoritmos de ML más eficientes y ligeros que puedan ejecutarse efectivamente en dispositivos con recursos limitados, paralelamente, se requieren métodos innovadores para la generación de datos sintéticos que complementen los datos del mundo real y mejoren la calidad del entrenamiento de modelos ML (Kulin et al., 2021). La adaptación rápida de modelos ML a cambios dinámicos en la red, incluyendo la reconfiguración dinámica y el manejo de la heterogeneidad del tráfico, representa otra área crítica de investigación (Zhou et al., 2023). La mejora de las técnicas de gestión del espectro basadas en ML para aumentar la eficiencia del uso de recursos radioeléctricos, además de, el desarrollo de métodos de detección de interferencias robustos y eficientes para entornos rurales complejos.

En el contexto de la mejora potencial, el desarrollo de plataformas de software que faciliten la implementación de ML en redes rurales emerge como una prioridad, estas plataformas deben abordar aspectos cruciales como la adquisición de datos, el entrenamiento de modelos y su implementación en dispositivos de borde (Shi et al., 2023), la exploración de nuevas arquitecturas de redes neuronales específicamente adaptadas a las particularidades de las redes rurales, incluyendo el uso de redes más pequeñas o arquitecturas jerárquicas, representa otra área prometedora de investigación (Kumar-Samanta et al., 2022), implementación de técnicas de aprendizaje federado para la optimización de redes de borde, donde se pueden entrenar modelos localmente sin compartir datos, manteniendo la privacidad del usuario (Mikola et al., 2023; Shi et al., 2023) y paralelamente, investigación en métodos de aprendizaje no supervisado y de refuerzo para la optimización en tiempo real de redes rurales y la gestión del espectro (Liu et al., 2020; Naser & Alavi, 2021).

La investigación en la aplicación de ML para la optimización de redes híbridas terrestres-satelitales representa una dirección prometedora para el futuro de la conectividad rural. Este campo emergente aborda desafíos cruciales como la gestión eficiente del handover entre diferentes tecnologías y la optimización del uso de recursos en sistemas híbridos, aspectos fundamentales para garantizar una conectividad continua y de alta calidad en áreas remotas (Ramírez-Arroyo et al., 2024). La complejidad de estos sistemas híbridos demanda el desarrollo de modelos de ML específicamente diseñados para la planificación estratégica de la expansión de la red, considerando factores críticos como la densidad poblacional, las características topográficas y las necesidades específicas de conectividad de cada región (Chaabane et al., 2024).

En el ámbito de la sostenibilidad energética, la aplicación de ML para la gestión inteligente de la energía en redes rurales está emergiendo como un campo de investigación prioritario, este enfoque incluye la optimización del uso de energías renovables y la implementación de estrategias avanzadas para la reducción del consumo energético (Ryo-Koblitz et al., 2024), paralelamente, la integración de la teoría de la información con el aprendizaje profundo para sistemas de comunicación inalámbricos representa una dirección innovadora que promete mejorar significativamente la eficiencia y rendimiento de las redes rurales (Mikola et al., 2023). Por otro lado, el desarrollo de métricas de evaluación específicamente diseñadas para capturar la complejidad y particularidades de las redes rurales constituye otra área crítica de investigación, son esenciales para medir con precisión el impacto real de las soluciones basadas en ML y proporcionar una base sólida para la comparación y mejora continua de diferentes aproximaciones (Kulin et al., 2021).

Complementariamente, la exploración de técnicas de meta-aprendizaje emerge como una dirección prometedora, enfocándose en facilitar la rápida adaptación de modelos ML a diversos escenarios y entornos rurales (Ramírez-Arroyo et al., 2024). A pesar de los desafíos existentes, las redes rurales presentan numerosas oportunidades para el desarrollo e innovación tecnológica, la expansión de la conectividad en áreas rurales puede reducir la brecha digital y promover el desarrollo socioeconómico, permitiendo el acceso a la educación, la atención médica y las oportunidades laborales, en el sector agrícola, la convergencia entre IoT, 5G y ML puede transformar la agricultura, mejorando la eficiencia de los cultivos y la gestión del ganado.

El surgimiento de nuevos modelos de negocio para operadores de redes y proveedores de servicios en áreas rurales representa otra oportunidad significativa, estos modelos innovadores, que incluyen la participación activa de la comunidad en la gestión de la red, están redefiniendo la manera en que se implementan y mantienen las infraestructuras de comunicación en zonas remotas (Chaoub et al., 2022), esta evolución se ve fortalecida por el desarrollo continuo de hardware y software especializado para entornos rurales, incluyendo dispositivos de bajo costo y alta eficiencia energética (Kumar-Samanta et al., 2022).

Finalmente, la revisión sistemática de la literatura ha revelado hallazgos fundamentales sobre la implementación del aprendizaje automático en redes rurales. Los desafíos técnicos más significativos incluyen las limitaciones en infraestructura, la complejidad topográfica, la escasez de espectro radioeléctrico y los elevados costos operativos, factores que obstaculizan significativamente el despliegue efectivo de redes en áreas rurales (Kulin et al., 2021; Chaoub et al., 2022), esta problemática se ve exacerbada por la escasez de personal cualificado y las restricciones inherentes a los dispositivos con recursos limitados, aspectos que demandan soluciones innovadoras y adaptadas al contexto rural (Chaabane et al., 2024).

En el ámbito específico del aprendizaje automático, las limitaciones más críticas se centran en la disponibilidad y calidad de los datos, la complejidad computacional, la generalización de los modelos, la adaptación a cambios dinámicos y los requisitos de energía son factores que limitan la implementación efectiva de soluciones ML en entornos rurales (Kulin et al., 2021; Almurshed et al., 2022; Chaabane et al., 2024) (). Sin embargo, a pesar de las limitaciones, ML ofrece un gran potencial para optimizar el rendimiento de las redes, mejorar la gestión del espectro, reducir el consumo de energía, predecir la demanda de tráfico, y habilitar nuevos servicios y aplicaciones en áreas rurales (Wang et al., 2020).

La importancia estratégica de la conectividad en áreas rurales es crucial para reducir la brecha digital y promover el desarrollo socioeconómico, facilitando el acceso

a la educación, la salud y las oportunidades de empleo (Chaoub et al., 2022; Chaabane et al., 2024; Ramírez-Arroyo et al., 2024; Pandey, 2024). Por otro lado, la optimización de la infraestructura, incluyendo la ubicación óptima de torres, el diseño de redes de retorno rentables y la integración de tecnologías como NTN (redes no terrestres) y FSO (comunicación óptica de espacio libre) son importantes para mejorar la conectividad en áreas rurales.

El aprendizaje federado ha emergido como una solución prometedora para el entrenamiento de modelos ML en dispositivos de borde, manteniendo la privacidad de los datos y reduciendo la dependencia de conexiones centralizadas (Almurshed et al., 2022; Shi et al., 2023; Lü, 2024). Además, se requiere un enfoque integral que considere la combinación de tecnologías (como redes celulares y satelitales), la optimización del espectro, el uso de energías renovables y la aplicación de ML en todos los niveles de la red para superar las limitaciones de conectividad (Chaoub et al., 2022; Ramírez-Arroyo et al., 2024). La gestión inteligente de recursos mediante algoritmos de ML, incluyendo el aprendizaje por refuerzo profundo, redes neuronales y optimización bayesiana, demuestra ser una aproximación efectiva para optimizar la asignación de recursos inalámbricos y mejorar la eficiencia energética de la red (Wang et al., 2020; Pandey, 2024).

La evolución hacia redes más inteligentes y adaptativas representa otro hallazgo significativo, la capacidad de las redes para adaptarse al entorno mediante técnicas avanzadas de ML, como la detección de actividad del usuario, la estimación de canales y el seguimiento de movilidad, está transformando la manera en que se gestionan y optimizan las infraestructuras de comunicación rurales, este avance hacia redes más inteligentes está facilitando una mejor respuesta a las necesidades cambiantes de las comunidades rurales y una utilización más eficiente de los recursos disponibles (Kulin et al., 2021).

Las implicaciones derivadas de los hallazgos presentados sugieren direcciones estratégicas fundamentales para el desarrollo futuro de redes rurales, en primera instancia, emerge la necesidad imperativa de priorizar el desarrollo de soluciones de conectividad de bajo costo y alta eficiencia energética específicamente adaptadas a entornos rurales, este enfoque debe considerar la integración innovadora de tecnologías preexistentes y el aprovechamiento de soluciones comerciales (COTS), estableciendo un equilibrio entre accesibilidad económica y rendimiento operativo (Chaoub et al., 2022; Ryo-Koblitz et al., 2024).

La eficiencia energética se posiciona como un pilar fundamental en el diseño y operación futura de redes rurales, esta priorización implica no solo la incorporación de fuentes de energía renovable sino también la implementación de estrategias avanzadas para la optimización del consumo energético. Paralelamente, el desarrollo de

algoritmos de ML más eficientes y ligeros emerge como una necesidad crítica, considerando las limitaciones de recursos en dispositivos rurales, la implementación distribuida de ML y las técnicas de reducción de complejidad en los modelos se presentan como aproximaciones prometedoras para abordar estos desafíos (Kulin et al., 2021; Zhang et al., 2022; Shi et al., 2023).

La colaboración multisectorial y la estandarización se revelan como elementos cruciales para el avance en el desarrollo de soluciones ML para redes rurales, esta colaboración debe integrar esfuerzos de investigadores, ingenieros, empresas y gobiernos, complementada por la estandarización de conjuntos de datos, métricas de evaluación y definición de problemas comunes, en este contexto, la inversión en la recopilación y procesamiento de datos de alta calidad en áreas rurales se vuelve fundamental para el entrenamiento efectivo de modelos ML, considerando la posibilidad de complementar datos reales con datos sintéticos cuando sea necesario (Kulin et al., 2021; Srivastava, 2023; Chaabane et al., 2024). La adaptación dinámica emerge como un requisito esencial para los modelos de ML en entornos rurales. Los modelos deben ser capaces de adaptarse dinámicamente a los cambios en el entorno de la red, lo que requiere técnicas de aprendizaje continuo y transferencia de aprendizaje (Kulin et al., 2021; Zhang et al., 2022; Chaabane et al., 2024).

Finalmente, la integración del ML en la planificación estratégica de redes rurales se presenta como una implicación fundamental para el desarrollo futuro, esta integración debe abarcar aspectos críticos como la optimización en la ubicación de torres, el diseño eficiente de rutas y la gestión inteligente de recursos, la consideración holística de estos elementos permitirá desarrollar infraestructuras de red más resilientes y adaptadas a las necesidades específicas de las comunidades rurales (Zhang et al., 2022; Chaabane et al., 2024).

CONCLUSIONES

La presente investigación ha permitido identificar que la aplicación del aprendizaje automático en la optimización de redes inalámbricas rurales representa una transformación significativa en la forma de abordar los desafíos de conectividad en áreas remotas. Los algoritmos de ML, particularmente el aprendizaje federado, las redes neuronales y el aprendizaje por refuerzo, han demostrado una notable efectividad en la gestión dinámica de recursos, la predicción de patrones de tráfico y la optimización energética, esta integración tecnológica está permitiendo superar limitaciones tradicionales mediante soluciones adaptativas que responden a las condiciones específicas de los entornos rurales, aunque la implementación exitosa de estas soluciones continúa enfrentando obstáculos significativos en términos de disponibilidad de datos,

capacidades computacionales y adaptabilidad a entornos dinámicos.

El análisis de las tendencias actuales revela una convergencia tecnológica prometedora que integra ML con innovaciones emergentes como 5G, IoT y edge computing, estableciendo las bases para ecosistemas de conectividad más robustos y eficientes, esta sinergia tecnológica está facilitando el desarrollo de soluciones más sofisticadas para la optimización de redes rurales, permitiendo una mejor gestión de recursos y una mayor eficiencia operativa, sin embargo, la investigación también ha identificado brechas críticas que requieren atención urgente, especialmente en el desarrollo de algoritmos más eficientes y adaptables a las limitaciones de recursos características de los entornos rurales, donde la sostenibilidad y la eficiencia energética emergen como factores cruciales que demandan soluciones innovadoras basadas en ML.

Los hallazgos subrayan la importancia de adoptar un enfoque holístico en la implementación de soluciones ML para redes rurales, considerando no solo los aspectos técnicos sino también los factores socioeconómicos y ambientales. La investigación destaca que el éxito en la optimización de redes rurales mediante ML requiere una comprensión profunda de las necesidades específicas de las comunidades rurales, así como de las limitaciones y oportunidades presentes en estos entornos, este entendimiento debe traducirse en el desarrollo de soluciones tecnológicas que sean no solo técnicamente efectivas sino también sostenibles y accesibles para las comunidades rurales, considerando aspectos como el costo de implementación, la facilidad de mantenimiento y la capacidad de adaptación a diferentes contextos geográficos y sociales.

Las perspectivas futuras en este campo sugieren un papel cada vez más prominente del ML en la optimización de redes rurales, con un énfasis particular en el desarrollo de soluciones más inteligentes y autónomas, la evolución de las tecnologías de ML, combinada con avances en áreas como la computación distribuida y las comunicaciones satelitales, promete abrir nuevas posibilidades para mejorar la conectividad rural, sin embargo, el éxito a largo plazo dependerá de la capacidad para abordar los desafíos identificados, especialmente en términos de eficiencia energética, escalabilidad y adaptabilidad, la colaboración entre academia, industria y comunidades rurales será fundamental para desarrollar soluciones que no solo sean técnicamente avanzadas sino también sostenibles y alineadas con las necesidades reales de las poblaciones rurales.

REFERENCIAS BIBLIOGRÁFICAS

- Almurshed, O., Patros, P., Huang, V., Mayo, M., Ooi, M., & Chard, R. (2022). Adaptive Edge-Cloud Environments for Rural AI. 2022 IEEE International Conference on Services Computing (SCC), 74-83. <https://www.doi.org/10.1109/scc55611.2022.00023>
- Chaabane, F., Réjichi, S., Salem, H. B., Elmabrouk, H., & Tupin, F. (2024). Strategic Planning of Rural Telecommunication Infrastructure: A Multi-Source Data Fusion and Optimization Model. *Spatial Inf. Sci.*, 48(1), 73–78. <https://www.doi.org/10.5194/isprs-archives-xlvi-ii-1-2024-73-2024>
- Chandra-Gangwar, R., & Singh, R. (2023). Machine Learning Algorithms from Wireless Sensor Network's Perspective. En *Wireless Sensor Network's Perspective*. IntechOpen. <https://doi.org/http://dx.doi.org/10.5772/intechopen.111417>
- Chaoub, A., Giordani, M., Lall, B., Bhatia, V., Kliks, A., & Mendes, L. (2022). 6G for Bridging the Digital Divide: Wireless Connectivity to Remote Areas. *IEEE Wireless Communications*, 29(1), 160-168. <https://www.doi.org/10.1109/mwc.001.2100137>
- Dreifuerst, R. M., Daulton, S., Qian, Y., Varkey, P., Balandat, M., & Kasturia, S. (2021). Optimizing Coverage and Capacity in Cellular Networks using Machine Learning. 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 8138-8142. <https://doi.org/10.1109/ICASSP39728.2021.9414155>
- Kulin, M., Kazaz, T., De-Poorter, E., & Moerman, I. (2021). A Survey on Machine Learning-Based Performance Improvement of Wireless Networks: PHY, MAC and Network Layer. *Electronics*, 10(3). <https://doi.org/10.3390/electronics10030318>
- Kumar-Samanta, R., Sadhukhan, B., Samaddar, H., Sarkar, S., Koner, C., & Ghosh, M. (2022). Scope of machine learning applications for addressing the challenges in next-generation wireless networks. *CAAI Transactions on Intelligence Technology*, 7(3), 395 - 418. <https://doi.org/10.1049/cit2.12114>
- Liu, D., Sun, C., Yang, C., & Hanzo, L. (2020). Optimizing Wireless Systems Using Unsupervised and Reinforced-Unsupervised Deep Learning. *IEEE Network*, 34(4), 270-277. <https://doi.org/10.1109/MNET.001.1900517>
- Lü, M. (2024). Application of machine learning algorithms in resource allocation for wireless communications. *Applied and Computational Engineering*, 37-42. <https://www.doi.org/10.54254/2755-2721/102/20240966>

- Mikola, V., Andrii, P., Andrii, O., & Diana, N. (2023). Optimization of intelligent telecommunication networks. *Visnik Hmel'nic'kogo nacional'nogo universitetu*, 1, 33-41. <https://doi.org/10.31891/2307-5732-2023-317-1-33-41>
- Naser, M. Z., & Alavi, A. H. (2021). Error Metrics and Performance Fitness Indicators for Artificial Intelligence and Machine Learning in Engineering and Sciences. *Architecture, Structures and Construction*, 3, 499-517. <https://doi.org/10.1007/s44150-021-00015-8>
- Ojo, S., Sari, A., & Ojo, T. P. (2022). Path Loss Modeling: A Machine Learning Based Approach Using Support Vector Regression and Radial Basis Function Models. *Open Journal of Applied Sciences*, 12(6). <https://doi.org/10.4236/ojapps.2022.126068>
- Pandey, S. (2024). Optimizing UAV-Assisted Relaying through Split Learning for Enhanced Distributed Inference in IoT-Based Ecological Monitoring. *Acceleron Aerospace Journal*, 3(3). <https://doi.org/10.61359/11.2106-2446>
- Pirinen, P., Saarnisaari, H., Beek, J. v., Matinmikko-Blue, M., Nilsson, R., & Latva-aho, M. (2019). Wireless Connectivity for Remote and Arctic Areas – Food for Thought. 2019 16th International Symposium on Wireless Communication Systems (ISWCS), 43-47. <http://dx.doi.org/10.1109/ISWCS.2019.8877348>
- Ramírez-Arroyo, A., López, M., Rodríguez, I., Bro-Damsgaard, S., & Mogensen, P. (2024). Multi-Connectivity Solutions for Rural Areas: Integrating Terrestrial 5G and Satellite Networks to Support Innovative IoT Use Cases. *arXiv*. <https://www.doi.org/10.48550/arxiv.2411.06979>
- Ryo-Koblitz, A., Maggi, L., & Andrews, M. (2024). Reducing the Environmental Impact of Wireless Communication via Probabilistic Machine Learning. *Proceedings of the AAAI Symposium Series*, 2(1), 89-93. <https://doi.org/10.1609/aaais.v2i1.27654>
- Shi, Y., Lian, L., Shi, Y., Wang, Z., Zhou, Y., Fu, L., Bai, L., Zhang, J., & Zhang, W. (2023). Machine Learning for Large-Scale Optimization in 6G Wireless Networks. *arXiv.org*. <https://www.doi.org/10.48550/arXiv.2301.03377>
- Srivastava, M. (2023). Adapting Machine Learning Techniques for Low-Resource Settings in Developing Countries: A Multidisciplinary Approach. *OSF PREPRINTS*. <https://www.doi.org/10.31219/osf.io/62rbp>
- Temim, S., Talbi, L., & Bensebaa, F. (2023). Analysis and Multiobjective Optimization of a Machine Learning Algorithm for Wireless Telecommunication. *Telecom*, 4(2), 219-235. <https://doi.org/10.3390/telecom4020013>
- Wang, J., Jiang, C., Zhang, H., Ren, Y., Chen, K.-C., & Hanzo, L. (2020). Thirty Years of Machine Learning: The Road to Pareto-Optimal Wireless Networks. *IEEE Communications Surveys & Tutorials*, 22(3), 1472-1514. <https://doi.org/10.1109/COMST.2020.2965856>
- Zhang, S., Yin, B., Zhang, W., & Cheng, Y. (2022). Topology Aware Deep Learning for Wireless Network Optimization. *IEEE Transactions on Wireless Communications*, 21(11), 9791 - 9805. <https://www.doi.org/10.1109/twc.2022.3179352>
- Zhou, H., Erol-Kantarci, M., Liu, Y., & Poor, H. V. (2023). A Survey on Model-based, Heuristic, and Machine Learning Optimization Approaches in RIS-aided Wireless Networks. *IEEE Communications Surveys & Tutorials*, 26(2), 781-823. <https://arxiv.org/abs/2303.14320>