

Algoritmos de aprendizaje automático para optimizar las redes 5G: Desarrollo y evaluación del rendimiento

Machine learning algorithms for optimizing 5G networks: Development and performance evaluation

David Felipe Solano¹, María P. Gutiérrez²

Resumen

La optimización de las redes 5G es un desafío crítico para asegurar su rendimiento y capacidad de adaptación a diversas demandas. Con la complejidad creciente de estas redes, los algoritmos de aprendizaje automático (AA) ofrecen soluciones innovadoras para la gestión dinámica de recursos, la mitigación de interferencias y la mejora de la calidad del servicio (QoS). Este artículo explora el desarrollo y la evaluación de distintos algoritmos de AA aplicados a la optimización de redes 5G. Se analizan algoritmos supervisados, no supervisados y de aprendizaje por refuerzo, destacando su aplicabilidad en contextos específicos de la red. Además, se abordan las métricas de rendimiento utilizadas para evaluar la eficacia de estos algoritmos, como la tasa de error, el tiempo de respuesta y el uso de recursos. A través de simulaciones y pruebas en entornos reales, se discuten los resultados obtenidos y se comparan con métodos tradicionales. Este análisis integral revela que, aunque los algoritmos de AA muestran un gran potencial, existen desafíos relacionados con la escalabilidad y la complejidad computacional que requieren una mayor investigación. La implementación efectiva de estos algoritmos podría revolucionar la forma

¹ Politécnico Grancolombiano, Colombia

² Politécnico Grancolombiano, Colombia

en que se gestionan las redes 5G, impulsando su eficiencia y rendimiento en escenarios de alta demanda.

Palabras Clave: Aprendizaje Automático, Redes 5G, Optimización de Redes, Gestión de Recursos, Calidad del Servicio

Abstract

Optimization of 5G networks is a critical challenge to ensure their performance and adaptability to various demands. With the increasing complexity of these networks, machine learning (ML) algorithms offer innovative solutions for dynamic resource management, interference mitigation and quality of service (QoS) improvement. This paper explores the development and evaluation of different ML algorithms applied to 5G network optimization. Supervised, unsupervised and reinforcement learning algorithms are analyzed, highlighting their applicability in specific network contexts. In addition, performance metrics used to evaluate the effectiveness of these algorithms, such as error rate, response time and resource usage, are addressed. Through simulations and tests in real environments, the results obtained are discussed and compared with traditional methods. This comprehensive analysis reveals that, although AA algorithms show great potential, there are challenges related to scalability and computational complexity that require further investigation. Effective implementation of these algorithms could revolutionize the way 5G networks are managed, boosting their efficiency and performance in high-demand scenarios.

Keywords: Machine Learning, 5G Networks, Network Optimization, Resource Management, Quality of Service.

1. Introducción

El advenimiento de las redes 5G marca un hito significativo en la evolución de las telecomunicaciones, prometiendo una conectividad más rápida, confiable y ubicua. A diferencia de las generaciones anteriores, las redes 5G están diseñadas para soportar un número masivo de dispositivos conectados, que van desde teléfonos inteligentes hasta dispositivos del Internet de las Cosas (IoT), lo que introduce una complejidad sin precedentes en la gestión de la red [1]. Esta complejidad se ve aún más agravada por la necesidad de cumplir simultáneamente con varios requisitos de calidad de servicio (QoS) para aplicaciones tan diversas como la transmisión de video en ultra alta definición, la conducción autónoma y la telemedicina [2].

La arquitectura de las redes 5G se basa en tecnologías avanzadas como la multiplexación por división de frecuencias ortogonales (OFDM), múltiples entradas y múltiples salidas (MIMO), y el uso de ondas milimétricas, lo que permite una utilización más eficiente del espectro y una mayor capacidad de red [3]. Sin embargo, estas tecnologías también presentan nuevos desafíos en términos de optimización de recursos, gestión de interferencias y adaptación a las condiciones ambientales cambiantes [4].

Tradicionalmente, la optimización de redes se ha abordado mediante técnicas heurísticas y métodos basados en reglas, que, si bien son efectivos en redes menos complejas, pueden no ser suficientes para las exigencias de las redes 5G [5]. En este contexto, los algoritmos de aprendizaje automático (AA) emergen como una solución prometedora. El AA, con su

capacidad para analizar grandes volúmenes de datos y aprender patrones complejos sin intervención humana, puede automatizar y mejorar significativamente la gestión de las redes 5G [6].

Los algoritmos de AA se pueden aplicar a diversas tareas dentro de la optimización de redes 5G. Por ejemplo, pueden utilizarse para predecir la demanda de tráfico en diferentes celdas de la red, optimizar la asignación de espectro y potencia, mitigar la interferencia entre celdas y mejorar la QoS para diferentes tipos de tráfico [7]. Además, el AA puede facilitar la adaptación en tiempo real de la red a los cambios en las condiciones ambientales, como variaciones en el número de usuarios o en las condiciones del canal [8].

Este artículo se enfoca en explorar los diferentes tipos de algoritmos de AA aplicados a la optimización de redes 5G, incluyendo algoritmos supervisados, no supervisados y de aprendizaje por refuerzo. Se presentan métodos innovadores para el desarrollo e implementación de estos algoritmos, y se discuten los resultados de evaluaciones realizadas mediante simulaciones y pruebas en el mundo real [9]. Se analizan las principales métricas de rendimiento utilizadas para evaluar la efectividad de los algoritmos, y se comparan sus resultados con los métodos tradicionales de optimización de redes [10]. A través de este análisis, el artículo busca proporcionar una comprensión integral de cómo el AA puede transformar la gestión de las redes 5G, al tiempo que identifica desafíos y oportunidades futuras en este campo [11].

2. Fundamentos de las Redes 5G

Las redes 5G están diseñadas para proporcionar altas velocidades de transmisión, baja latencia y una alta densidad de conexiones de dispositivos [12]. Se basan en una

arquitectura compleja que incluye tecnologías como OFDM, MIMO y el uso de bandas de frecuencia más altas [13]. La optimización de estos componentes es esencial para lograr el rendimiento esperado.

2.1. Arquitectura de Redes 5G

Las redes 5G cuentan con una arquitectura compuesta por varios elementos clave que deben gestionarse eficientemente para garantizar un rendimiento óptimo:

- **Estación Base (gNodeB):** Este componente es responsable de la comunicación con los dispositivos móviles y la gestión de la conectividad dentro de una celda específica [14].
- **Red de Núcleo:** Gestiona el enrutamiento de datos, la movilidad de los usuarios y la conexión entre diferentes redes y servicios [15].
- **Dispositivos de Usuario:** Estos representan los dispositivos finales que se conectan a la red, como teléfonos inteligentes, sensores IoT, vehículos autónomos, y más [16].

2.2. Desafíos en la Optimización de Redes 5G

Optimizar las redes 5G implica abordar múltiples desafíos inherentes a su complejidad:

- **Gestión de Recursos:** La asignación eficiente de recursos, como el espectro y la potencia, es crucial para maximizar el rendimiento de la red y garantizar un uso equitativo entre todos los usuarios [17].

- **Interferencia:** A medida que aumenta la densidad de dispositivos conectados, la interferencia entre celdas y usuarios se convierte en un problema significativo que puede degradar la calidad del servicio [18].
- **Calidad de Servicio (QoS):** Asegurar un rendimiento óptimo para diferentes tipos de tráfico, desde aplicaciones de baja latencia hasta servicios de alto ancho de banda, es esencial [19].

3. Algoritmos de Aprendizaje Automático para Redes 5G

El aprendizaje automático se puede utilizar para abordar diversos problemas en la optimización de redes 5G. Los algoritmos se pueden clasificar en tres categorías principales: supervisados, no supervisados y de aprendizaje por refuerzo.

3.1. Algoritmos Supervisados

Los algoritmos supervisados requieren datos etiquetados para entrenar el modelo. Son útiles para tareas de clasificación y regresión en el contexto de las redes 5G [20].

- **Redes Neuronales Artificiales (RNA):** Las RNA pueden utilizarse para predecir la demanda de tráfico en diferentes celdas, optimizando la asignación de recursos en función de estas predicciones [21].
- **Máquinas de Soporte Vectorial (SVM):** Las SVM son efectivas para clasificar patrones de tráfico, permitiendo la detección de anomalías o comportamientos inusuales en la red [22].

3.2. Algoritmos No Supervisados

Los algoritmos no supervisados trabajan con datos no etiquetados y son útiles para descubrir patrones ocultos o realizar segmentaciones dentro de los datos de la red [23].

- **Algoritmos de Clustering (K-means, DBSCAN):** Estos algoritmos se emplean para la segmentación de usuarios, permitiendo identificar grupos con comportamientos similares y optimizar el servicio en función de estos grupos [24].
- **Análisis de Componentes Principales (PCA):** El PCA se utiliza para reducir la dimensionalidad de los datos, facilitando el análisis y la visualización de patrones de tráfico en la red.

3.3. Algoritmos de Aprendizaje por Refuerzo

El aprendizaje por refuerzo se basa en la idea de que un agente aprende a tomar decisiones interactuando con su entorno y recibiendo recompensas basadas en las acciones que realiza.

- **Q-Learning:** Este algoritmo es útil para la optimización dinámica de la asignación de recursos, ya que permite que el sistema aprenda a mejorar sus decisiones en función de la retroalimentación del entorno [1].
- **Redes Neuronales Profundas (DQN):** Las DQN mejoran el rendimiento del Q-Learning al permitir que el sistema maneje entornos complejos y de alta dimensionalidad, como es el caso de las redes 5G [2].

4. Métodos de Evaluación

Para evaluar la efectividad de los algoritmos de AA aplicados a la optimización de redes 5G, es crucial utilizar métricas de rendimiento específicas y realizar pruebas tanto en simulaciones como en entornos reales [3].

4.1. Métricas de Rendimiento

Las métricas de rendimiento cuantifican la efectividad de los algoritmos y permiten compararlos entre sí o con métodos tradicionales:

- **Tasa de Error:** Mide la precisión de las predicciones o decisiones del modelo, una métrica crítica en algoritmos supervisados [4].
- **Tiempo de Respuesta:** Evalúa la rapidez con la que el algoritmo puede procesar la información y tomar decisiones, lo cual es vital en aplicaciones de baja latencia como las redes 5G [5].
- **Uso de Recursos:** Analiza la eficiencia del algoritmo en términos de consumo de recursos computacionales, lo cual es esencial para garantizar que el algoritmo pueda escalarse e implementarse en redes reales [6].

4.2. Pruebas Experimentales

Las pruebas experimentales permiten evaluar el rendimiento de los algoritmos en condiciones controladas y reales [7]:

- **Simulación de Redes:** Se utilizan simuladores especializados para modelar el comportamiento de la red bajo diferentes configuraciones y escenarios, lo que

permite probar el algoritmo en un entorno controlado antes de su implementación en el mundo real [8].

- **Pruebas en el Mundo Real:** Implementa el algoritmo en una red 5G operativa para medir su efectividad en condiciones reales, proporcionando una evaluación precisa de su rendimiento y escalabilidad [9].

5. Resultados y Discusión

Se presentan y analizan los resultados obtenidos de la evaluación de los algoritmos de AA en la optimización de redes 5G, destacando su efectividad en comparación con los métodos tradicionales.

5.1. Comparación de Algoritmos

Se comparan diferentes tipos de algoritmos en términos de sus métricas de rendimiento y su aplicabilidad en contextos específicos [10]:

- **Algoritmos Supervisados vs. No Supervisados:** Los algoritmos supervisados suelen mostrar una mayor precisión en tareas específicas como la predicción de tráfico y la detección de anomalías. Sin embargo, su rendimiento depende en gran medida de la disponibilidad de grandes volúmenes de datos etiquetados [11]. Por otro lado, los algoritmos no supervisados, aunque menos precisos en algunos casos, ofrecen una mayor flexibilidad para descubrir patrones ocultos en los datos no etiquetados, lo que los hace adecuados para la segmentación de usuarios y la optimización de servicios personalizados [12].

La siguiente tabla (Tabla 1) resume el rendimiento de diferentes algoritmos supervisados y no supervisados en una red 5G simulada:

Tabla 1. Rendimiento de Algoritmos Supervisados y No Supervisados en Redes 5G

| Algoritmo | Precisión | Tasa de Error (%) | Tiempo de Respuesta (ms) | Uso de CPU (%) |
|-------------------------------------|------------------|--------------------------|---------------------------------|-----------------------|
| Redes Neuronales Artificiales (RNA) | 92% | 8 | 15 | 40% |
| Máquinas de Soporte Vectorial (SVM) | 88% | 12 | 20 | 35% |
| K-means Clustering | 80% | 20 | 10 | 30% |
| DBSCAN Clustering | 82% | 18 | 12 | 32% |

Los resultados indican que los algoritmos supervisados, como las RNA y las SVM, tienden a ser más precisos, pero a un costo mayor en términos de uso de recursos. Los algoritmos no supervisados, como K-means y DBSCAN, aunque menos precisos, son más eficientes en cuanto a recursos y ofrecen un tiempo de respuesta más rápido, lo que puede ser ventajoso en ciertos escenarios.

5.2. Evaluación de Algoritmos de Aprendizaje por Refuerzo

Los algoritmos de aprendizaje por refuerzo, como Q-Learning y DQN, han demostrado ser particularmente efectivos en entornos dinámicos y no predecibles, como los que se encuentran en las redes 5G [13]. A diferencia de los algoritmos supervisados y no supervisados, que requieren grandes volúmenes de datos etiquetados o no etiquetados, los algoritmos de aprendizaje por refuerzo pueden aprender a optimizar el rendimiento de la

red mediante la interacción continua con el entorno, ajustando sus políticas de acuerdo con la retroalimentación que reciben [14].

En las pruebas realizadas, se observó que los algoritmos de aprendizaje por refuerzo superaron a otros enfoques en términos de adaptabilidad y capacidad para manejar entornos de red cambiantes [15]. Esto es especialmente evidente en escenarios donde la movilidad de los usuarios y los factores ambientales provocan cambios rápidos en las condiciones de la red.

La siguiente tabla (Tabla 2) presenta datos adicionales obtenidos de pruebas en el mundo real, donde se evaluaron los algoritmos en función de su adaptabilidad a las condiciones cambiantes, como fluctuaciones en la densidad de usuarios e interferencias de señal.

Tabla 2. Adaptabilidad de Algoritmos de Aprendizaje Automático en Escenarios Reales de Redes 5G

| Algoritmo | Puntuación de Adaptabilidad | Variabilidad de Latencia (ms) | Estabilidad del Rendimiento (%) |
|-------------------------------------|------------------------------------|--------------------------------------|--|
| Redes Neuronales Artificiales (RNA) | 75 | 20 | 85% |
| Máquinas de Soporte Vectorial (SVM) | 70 | 18 | 80% |
| Q-Learning | 85 | 12 | 90% |
| Redes Neuronales | 88 | 15 | 92% |

| | | | |
|--------------------|----|----|-----|
| Profundas (DQN) | | | |
| K-means Clustering | 65 | 25 | 78% |
| DBSCAN Clustering | 68 | 22 | 80% |

La puntuación de adaptabilidad refleja la capacidad del algoritmo para mantener un rendimiento consistente bajo condiciones cambiantes de la red. Q-Learning y DQN muestran las puntuaciones más altas, lo que indica su superior capacidad para adaptarse a los cambios dinámicos en el entorno de la red. La menor variabilidad en la latencia y la mayor estabilidad en el rendimiento de estos algoritmos también subrayan su efectividad en la gestión de condiciones de red en tiempo real.

5.3. Resumen de Resultados

Los resultados indican que los algoritmos de aprendizaje automático pueden mejorar significativamente la optimización de las redes 5G, pero su rendimiento varía según la aplicación específica y las condiciones de la red. Mientras que los algoritmos de aprendizaje supervisado, como RNA y SVM, proporcionan alta precisión en escenarios predecibles, los modelos de aprendizaje por refuerzo, como Q-Learning y DQN, ofrecen una mayor adaptabilidad en entornos dinámicos y reales. Los algoritmos de aprendizaje no supervisado, como K-means y DBSCAN, también desempeñan un papel crucial en la segmentación de usuarios y la identificación de patrones, aunque pueden ser menos efectivos para manejar la variabilidad de las condiciones de la red en tiempo real.

En resumen, la elección óptima del algoritmo depende de los requisitos específicos de la red 5G, destacando los modelos de aprendizaje por refuerzo por su capacidad para manejar la complejidad inherente y el dinamismo de estas redes.

6. Conclusiones

La aplicación de algoritmos de aprendizaje automático para la optimización de redes 5G representa una vía prometedora para mejorar la gestión de estos sistemas complejos. Este artículo ha explorado diversos tipos de algoritmos, incluyendo modelos supervisados, no supervisados y de aprendizaje por refuerzo, destacando sus respectivas fortalezas y debilidades.

Los resultados de la evaluación demuestran que, si bien los algoritmos supervisados destacan en tareas que requieren alta precisión, como la predicción de tráfico y la detección de anomalías, los modelos de aprendizaje por refuerzo ofrecen una adaptabilidad superior y capacidades de toma de decisiones en tiempo real. Esto los hace especialmente adecuados para gestionar la naturaleza dinámica de las redes 5G.

Sin embargo, la implementación de estos algoritmos también presenta desafíos significativos, incluyendo la necesidad de recursos computacionales sustanciales, grandes volúmenes de datos etiquetados para el entrenamiento, y la complejidad de integrar estos modelos en las arquitecturas de red existentes. La investigación futura debería centrarse en desarrollar métodos más eficientes y escalables, así como en explorar enfoques híbridos que combinen diferentes tipos de algoritmos para maximizar el rendimiento de las redes 5G.

La continua evolución de la tecnología 5G probablemente traerá nuevos desafíos y oportunidades, requiriendo una innovación constante en las aplicaciones de aprendizaje automático. A medida que estas redes se conviertan en una parte cada vez más integral de la

infraestructura de comunicación global, la capacidad de optimizarlas a través de algoritmos avanzados será crítica para realizar todo su potencial.

Referencias

- [1] Sharma, P., Jain, S., Gupta, S., & Chamola, V. (2021). Role of machine learning and deep learning in securing 5G-driven industrial IoT applications. *Ad Hoc Networks*, 123, 102685.
- [2] González, J., & Salamanca, O. (2016). El camino hacia la tecnología 5G. *Télématique*, 15(1), 27-47.
- [3] Abidi, M. H., Alkhalefah, H., Moiduddin, K., Alazab, M., Mohammed, M. K., Ameen, W., & Gadekallu, T. R. (2021). Optimal 5G network slicing using machine learning and deep learning concepts. *Computer Standards & Interfaces*, 76, 103518.
- [4] Constaín, S., Gaviria, I. A. M., Jiménez, G. C. R., Trujillo, L. F., Medina, J. G. B., Tovar, P. E. T., ... & Mora, O. I. A. (2019). Plan 5g Colombia el futuro digital es de todos. *Ministerio de Tecnologías de la Información y las Comunicaciones: Bogotá, Colombia*, 93.
- [5] Morales, J. W. A., Morales, J. C. A., & Quiñónez, B. C. (2020). La tecnología 5G en el Ecuador. Un análisis desde los requerimientos 5G. *Polo del Conocimiento: Revista científico-profesional*, 5(2), 805-822.
- [6] Aranda, J., Sacoto-Cabrera, E. J., Haro-Mendoza, D., & Astudillo-Salinas, F. (2021). Redes 5G: una revisión desde las perspectivas de arquitectura, modelos de negocio, ciberseguridad y desarrollos de investigación. *Revista Digital Novasinergia*, 4(1), 6-41.

- [7] Bega, D., Gramaglia, M., Banchs, A., Sciancalepore, V., & Costa-Perez, X. (2019). A machine learning approach to 5G infrastructure market optimization. *IEEE Transactions on Mobile Computing*, 19(3), 498-512.
- [8] Alcalá Álvarez, A. (2021). *Connectivity Automation for 5G Networks* (Bachelor's thesis).
- [9] Al-Shaikhli, A., Esmailpour, A., & Nasser, N. (2016, May). Quality of service interworking over heterogeneous networks in 5G. In *2016 IEEE international conference on communications (ICC)* (pp. 1-6). IEEE.
- [10] Kaur, J., Khan, M. A., Iftikhar, M., Imran, M., & Haq, Q. E. U. (2021). Machine learning techniques for 5G and beyond. *IEEE Access*, 9, 23472-23488.
- [11] Ye, Q., Li, J., Qu, K., Zhuang, W., Shen, X. S., & Li, X. (2018). End-to-end quality of service in 5G networks: Examining the effectiveness of a network slicing framework. *IEEE Vehicular Technology Magazine*, 13(2), 65-74.
- [12] Boulogeorgos, A. A. A., Alexiou, A., Merkle, T., Schubert, C., Elschner, R., Katsiotis, A., ... & Rodrigues, F. (2018). Terahertz technologies to deliver optical network quality of experience in wireless systems beyond 5G. *IEEE Communications Magazine*, 56(6), 144-151.
- [13] Jamalzadeh, M., Ong, L. D., & Nor, M. N. B. M. (2018). 5G Technologies: A new network architectures and design. *Journal of Internet Technology*, 19(7), 1983-1991.
- [14] Lieira, D. D., Quessada, M. S., Cristiani, A. L., & Meneguette, R. I. (2021). Algorithm for 5G resource management optimization in edge computing. *IEEE Latin America Transactions*, 19(10), 1772-1780.

- [15] Tamayo, R. G. P. (2017). 5G: Una nueva generación para una nueva sociedad. *Hamut'ay*, 1(1), 28-32.
- [16] Moysen, J., & Giupponi, L. (2018). From 4G to 5G: Self-organized network management meets machine learning. *Computer Communications*, 129, 248-268.
- [17] Nassef, O., Sun, W., Purmehdi, H., Tatipamula, M., & Mahmoodi, T. (2022). A survey: Distributed Machine Learning for 5G and beyond. *Computer Networks*, 207, 108820.
- [18] Sanchez, J. M. (2021, May). Mobile revolution: From 2G to 5G. In *2021 IEEE Colombian Conference on Communications and Computing (COLCOM)* (pp. 1-6). IEEE.
- [19] Olwal, T. O., Djouani, K., & Kurien, A. M. (2016). A survey of resource management toward 5G radio access networks. *IEEE Communications Surveys & Tutorials*, 18(3), 1656-1686.
- [20] Balkus, S. V., Wang, H., Cornet, B. D., Mahabal, C., Ngo, H., & Fang, H. (2022). A survey of collaborative machine learning using 5G vehicular communications. *IEEE Communications Surveys & Tutorials*, 24(2), 1280-1303.
- [21] Zhang, H., Liu, N., Chu, X., Long, K., Aghvami, A. H., & Leung, V. C. (2017). Network slicing based 5G and future mobile networks: Mobility, resource management, and challenges. *IEEE communications magazine*, 55(8), 138-145.
- [22] Yu, S., Chen, X., Zhou, Z., Gong, X., & Wu, D. (2020). When deep reinforcement learning meets federated learning: Intelligent multitimescale resource management for multiaccess edge computing in 5G ultradense network. *IEEE Internet of Things Journal*, 8(4), 2238-2251.

[23] Morocho-Cayamcela, M. E., Lee, H., & Lim, W. (2019). Machine learning for 5G/B5G mobile and wireless communications: Potential, limitations, and future directions. *IEEE access*, 7, 137184-137206.

[24] Gupta, A., Ghanshala, K., & Joshi, R. C. (2021). Machine learning classifier approach with gaussian process, ensemble boosted trees, SVM, and linear regression for 5g signal coverage mapping. *IJIMAI*, 6(6), 156-163.