

Machine Learning en la transformación digital de las telecomunicaciones: aplicaciones y desafíos

Emerson Yezith Gutiérrez Alvarado¹
Manuel Leonardo de Jesus Castro Barinas²

Resumen

La transformación digital ha cambiado la industria de las telecomunicaciones. Esto ha generado nuevos desafíos en la gestión y organización de procesos, además de afectar la seguridad en las redes. En este contexto el Machine Learning (ML) se consolida como una solución tecnológica clave. En el presente artículo se busca investigar la influencia del Machine Learning en la transformación digital de las telecomunicaciones, analizando sus principales usos y cuáles son los retos asociados para su aplicación. Con este propósito, se diseñó una revisión narrativa de literatura científica reciente, además de ser complementada con fuentes clásicas publicadas en bases de datos como como Scopus, IEEE Xplore y ScienceDirect. Al analizar los resultados se evidencia que el Machine Learning ayuda significativamente a la mejora de procesos predictivos y de optimización, conexión de redes, además de fortalecer la ciberseguridad gracias a la detección de anomalías a tiempo real. No obstante, la implementación efectiva del Machine Learning presenta 3 limitaciones importantes: infraestructura tecnológica deficiente, resistencia al cambio organizacional y escasez de talento especializado. Los resultados demuestran que el Machine Learning es una tecnología clave para la transformación digital, pero depende de una combinación de innovación, inversión tecnológica y formación profesional especializada.

Palabras claves: Machine Learning, transformación digital, telecomunicaciones, inteligencia artificial, análisis predictivo.

Machine Learning in the Digital Transformation of Telecommunications: Applications and Challenges

Abstract

Digital transformation has revolutionized the telecommunications industry, creating new challenges in process management and organization, as well as impacting network security. In this context, machine learning (ML) has emerged as a key technological solution. This article aims to investigate the influence of machine learning on the digital transformation of telecommunications, analyzing its primary applications and the challenges associated with its implementation. To this end, a narrative review of recent scientific literature was designed and supplemented with classic sources from databases such as Scopus, IEEE, Xplore, and ScienceDirect. The results reveal that Machine Learning significantly aids in improving predictive and optimization processes, network connectivity, and strengthening cybersecurity

¹ Estudiante, Ingeniería de Sistemas, Universidad Santo Tomás, Tunja, Colombia.
emerson.gutierrez@usantotomas.edu.co

² Docente, Facultad de Ingeniería de Sistemas, Universidad Santo Tomás, Tunja, Colombia.
manuel.castro@usantoto.edu.co

through real-time anomaly detection. However, the effective implementation of machine learning faces three major limitations: inadequate technological infrastructure, resistance to organizational change, and a shortage of specialized talent. The results demonstrate that machine learning is a key technology for digital transformation, but it depends on a combination of innovation, technological investment, and professional training.

Keywords: Machine Learning, digital transformation, telecommunications, artificial intelligence, predictive analytics.

1. Introducción

Tom M. Mitchell (1997, p. 2), uno de los autores más influyentes y pionero en el aprendizaje automático, define al Machine Learning como “el campo de estudio que da a las computadoras la capacidad de aprender sin ser programadas de manera explícita”. Por otro lado, Stuart Russell y Peter Norvig (2021) ubican al Machine Learning dentro del campo más amplio de la inteligencia artificial, que comprende el desarrollo de sistemas capaces de ejecutar tareas que requieren de inteligencia humana, como el reconocimiento de patrones, la toma de decisiones y la prevención de eventos.

La transformación digital, es entendida como la integración de tecnologías digitales de todas las áreas de una organización, genera cambios significativos en su funcionamiento y en la generación de valor (Vial, 2019). Sin embargo. Este proceso no está limitado únicamente a la incorporación de tecnologías, también implican transformaciones culturales y organizacionales. Teniendo en cuenta este enfoque el Machine Learning es un medio para alcanzar la mejora de experiencia del cliente, crear nuevos modelos de servicios y la mejora de costos operativos.

A pesar de los avances registrados en la literatura, las telecomunicaciones enfrentan importantes desafíos para incorporar de una forma eficaz el Machine Learning en sus procesos. Análisis recientes han encontrado varios obstáculos. Sarfraz, Khawaja y Waheed (2025) señalan que la adopción del Big Data y Machine Learning impulsa la innovación de procesos, pero solo cuando existe una cultura organizacional adecuada y personal capacitado. De igual forma, Hien y Tam (2025) resaltan que la infraestructura tecnológica es un factor crítico para el desarrollo de la economía digital, y su ausencia limita severamente la implementación de soluciones basadas en datos. Asimismo, Odeh et al. (2026) evidencian que, aunque la inteligencia artificial fortalece la seguridad cibernética y la eficiencia operativa, su adopción conlleva riesgos como los ataques adversariales a los propios sistemas de ML.

En Latinoamérica, los obstáculos asociados a la implementación del Machine Learning son más visibles. Un estudio del Banco Interamericano de Desarrollo (BID, 2025) indica que solo el 32% de las empresas de telecomunicaciones en la región cuentan con estrategias formales de inteligencia artificial, y menos del 15% han implementado soluciones de Machine Learning en producción. La falta de inversión en infraestructura tecnológica, la carencia de talento especializado y la resistencia al cambio organizacional se reitera como circunstancias limitantes en múltiples investigaciones (García-Peñalvo & Ramírez-Montoya, 2024; López & Fernández, 2025).

Con base en lo anterior se evidencia una brecha considerable entre el potencial del Machine Learning y como implementarlo en el sector de las telecomunicaciones, concretamente en contextos de desarrollo. Pese a que existen abundantes fuentes de literatura que hablan sobre los beneficios teóricos del Machine Learning, es menos frecuente encontrar estudios que analicen de manera integrada los factores que facilitan o dificultan su integración. Este desequilibrio de conocimientos es el que motiva el presente trabajo.

En este contexto surge la siguiente pregunta de investigación: ¿Cómo influye el Machine Learning en la transformación digital del sector de las telecomunicaciones y cuáles son los principales desafíos que limitan su implementación efectiva?

Para dar solución a esta pregunta, el presente artículo tiene como objetivo general evaluar el impacto del Machine Learning en la transformación digital del sector de las telecomunicaciones, reconociendo cuáles son sus principales aplicaciones y desafíos en su implementación. De manera que se pretende: (1) especificar cuáles son las principales aplicaciones del Machine Learning en la mejora de optimización de procesos, el análisis predictivo y la ciberseguridad; (2) buscar e identificar cuáles son las barreras tecnológicas organizacionales y humanas que restringen su implementación; y (3) Resumir cuáles son los hallazgos que la literatura científica tiene para ofrecer con el fin de presentar una visión integral del estado del arte.

El presente artículo se estructura de la siguiente manera. Después de esta introducción, se expone la metodología utilizada, la cual consiste en una revisión narrativa de literatura científica y fuentes académicas especializadas. Seguidamente, en la sección de resultados se presentan de manera objetiva los hallazgos principales organizados por categorías temáticas. Posteriormente, para la discusión, se analizan e interpretan estos resultados en relación con la literatura existente. Finalmente, se presentan las conclusiones donde se sintetizan los principales aportes del trabajo, cuales fueron sus limitantes y cuales pueden ser sus futuras líneas de investigación futura.

2. Metodología

1. Enfoque y tipo de investigación

El estudio se desarrolla adoptando un enfoque cualitativo, mediante una revisión narrativa de literatura científica. Esta clase de revisión permite resumir de una manera más crítica y descriptiva el conocimiento sobre un tema, facilitando la identificación de aplicaciones, tendencias y brechas de investigación (Ferrerías-Fernández et al., 2024). A diferencia de las revisiones sistemáticas, que se rigen por protocolos estrictos como PRISMA, la revisión narrativa brinda más flexibilidad de análisis a las preguntas de investigación y permite contextualizar hallazgos desde múltiples perspectivas (Canto & Canto, 2023).

Este estudio es de tipo exploratorio-descriptivo, dado que pretende identificar y caracterizar los principales usos del Machine Learning en el sector de las telecomunicaciones, además de encontrar cuáles son los factores que facilitan o dificultan su implementación. El estudio no pretende demostrar relaciones causales ni generalizar resultados de una manera estadística, sino ofrecer una comprensión del estado actual del tema.

2. Fuentes de información

La selección de las fuentes se realizó a partir de las siguientes bases de datos académicas:

- Scopus: base multidisciplinaria de alto impacto
- IEEE Xplore: especializada en ingeniería, electrónica y telecomunicaciones
- ScienceDirect: contenido de Elsevier en ciencias aplicadas
- Google Scholar: complementario para literatura gris y acceso abierto

El periodo de búsqueda abarcó publicaciones realizadas entre 2019 y 2025, con el propósito de recopilar información reciente en el campo del aprendizaje automático que va en constante evolución. Sin embargo, se utilizaron fuentes clásicas y de carácter fundacional como los trabajos de Tom M. Mitchell (1997), Christopher Bishop (2006) y Ian Goodfellow et al. (2016), debido a que continúan siendo referentes fundamentales para la comprensión de los conceptos básicos del Machine Learning.

3. Estrategia de búsqueda

Se utilizaron las siguientes cadenas de búsqueda combinando operadores booleanos:

- ("machine learning" OR "aprendizaje automático") AND ("telecommunications" OR "telecomunicaciones")
- ("digital transformation" OR "transformación digital") AND ("telecommunications" OR "telecomunicaciones")
- ("machine learning") AND ("5G" OR "6G" OR "wireless networks")
- ("deep learning") AND ("IoT" OR "edge computing" OR "federated learning")

4. Criterios de inclusión y exclusión

En la búsqueda se aplicaron lo siguiente criterios con la finalidad de garantizar la calidad, relevancia y pertinencia académica de las fuentes encontradas.

Tabla 1. Criterios de inclusión y exclusión

Criterios de inclusión	Criterios de exclusión
Artículos de revistas indexadas	Blogs, Wikipedia, páginas web sin respaldo académico
Libros académicos y capítulos de libro	Trabajos no fechados o sin autor identificable
Artículos derivados de conferencias científicas.	Fuentes anteriores a 2010 (excepto clásicas fundacionales)

Criterios de inclusión	Criterios de exclusión
Publicaciones en inglés o español	Estudios centrados exclusivamente en otros sectores (salud, finanzas, etc.) sin relación con telecomunicaciones
Acceso abierto o disponible institucionalmente	

5. Proceso de selección de documentos

El proceso de selección se llevó a cabo en cuatro fases (ver Figura 1):

- Fase 1 (Identificación): El proceso de selección de fuentes se llevó a cabo en cuatro fases progresivas. En la primera, correspondiente a la identificación, se realizaron búsquedas sistemáticas en las bases de datos seleccionadas, lo que permitió reunir un total de 3.494.772 registros preliminares como punto de partida.
- Fase 2 (Filtrado inicial): En la segunda fase, orientada al filtrado inicial, se procedió a eliminar los registros duplicados y se aplicaron criterios de restricción por año de publicación, comprendido entre 2019 y 2025, así como por idioma, limitándose a documentos en español e inglés. Como resultado, la muestra quedó reducida a 184.630 documentos.
- Fase 3 (Evaluación por título y resumen): La tercera fase consistió en la evaluación por título y resumen, durante la cual se analizó la pertinencia temática de cada documento en relación con el objeto de estudio. Aquellos que no abordaban directamente el vínculo entre el Machine Learning y las telecomunicaciones fueron descartados, obteniéndose así un conjunto de 120 documentos preseleccionados.
- Fase 4 (Lectura completa e inclusión final): Finalmente, en la cuarta fase se llevó a cabo la lectura completa de los 120 documentos restantes. Tras este análisis exhaustivo, se seleccionaron 60 fuentes principales que cumplían con la totalidad de los criterios de inclusión y aportaban elementos relevantes para dar respuesta a la pregunta de investigación planteada.

Figura 1. Diagrama de flujo del proceso de selección de documentos.



6. Categorías temáticas de análisis

Una vez seleccionadas las fuentes finales, se procedió a organizar la información en seis categorías temáticas, definidas a partir de la literatura revisada y en correspondencia con los objetivos del artículo:

Tabla 2. Categorías temáticas de análisis

Categoría	Descripción	Referentes clave
1. Fundamentos de Machine Learning	Definiciones, tipos de aprendizaje (supervisado, no supervisado, por refuerzo) y arquitecturas de redes neuronales	Mitchell (1997), Bishop (2006), Goodfellow et al. (2016), Sutton & Barto (2018)
2. ML en redes inalámbricas (5G/6G)	Optimización de redes, gestión del espectro, predicción de tráfico y asignación de recursos	Zhang & Letaief (2019), Shafi et al. (2017), Letaief et al. (2019), Saad et al. (2020)
3. Deep learning en telecomunicaciones	Uso de deep learning para beamforming, detección de señales, comunicación MIMO y procesamiento de señales	Mao et al. (2018), Alrabeiah & Alkhateeb (2021), LeCun et al. (2015)
4. Internet de las Cosas (IoT) y redes de sensores	Aplicaciones de ML en WSN, IoT masivo, redes de sensores y computación en el borde	Gubbi et al. (2013), Alsheikh et al. (2014), Bockelmann et al. (2016), Park et al. (2020)
5. Aprendizaje federado y Edge AI	Técnicas distribuidas para entrenar modelos sin compartir datos crudos, privacidad y computación en el borde	Yu et al. (2020), McMahan et al. (2017), Wang et al. (2021)
6. Desafíos de adopción	Barreras tecnológicas, organizacionales y humanas para la implementación de ML en telecomunicaciones	Sarfraz et al. (2025), López & Fernández (2025), BID (2025)

7. Procedimiento de análisis

Para el análisis de la información se empleó la técnica de análisis temático propuesta por Braun y Clarke (2006), adaptada al contexto de revisión narrativa. Este procedimiento consto de los siguientes 5 pasos:

- Lectura exhaustiva de cada una de las fuentes seleccionadas.
- Codificación inicial de los fragmentos relevantes para la pregunta de investigación.
- Agrupación de los códigos en seis categorías temáticas.
- Síntesis e interpretación de los hallazgos dentro de cada categoría.
- Contrastación entre fuentes para identificar consensos, discrepancias y vacíos de conocimiento.

8. Limitaciones metodológicas

Como todo enfoque metodológico la revisión narrativa conlleva ciertas limitantes inherentes en su diseño. Al no seguir protocolos sistemáticos como PRISMA, existe la posibilidad de que se introduzcan sesgos en la selección de fuentes o en la interpretación de los hallazgos (Ferrerías-Fernández et al., 2024). Así mismo, el enfoque cualitativo no permite cuantificar la magnitud de los efectos reportados en la literatura. No obstante, usar este enfoque resulta adecuado para el propósito del artículo ya que ofrece una aproximación integral y comprensible al estado del arte de un tema que, por su naturaleza emergente, aún se encuentra en proceso de consolidación dentro de la comunidad académica.

3. Resultados

En la siguiente sección se presentan los hallazgos obtenidos mediante la revisión de la literatura científica. Estos resultados están organizados en cinco categorías permiten comprender el impacto del Machine Learning en la transformación digital del sector de las telecomunicaciones.

1. Aplicaciones del Machine Learning en la optimización de procesos

La literatura revisada reporta múltiples aplicaciones del Machine Learning en la optimización de procesos dentro del sector de las telecomunicaciones. Los hallazgos se concentran en tres áreas principales:

a) Gestión de redes: Los algoritmos del Machine Learning se encargan del análisis de grandes volúmenes de datos generados por las infraestructuras de red para identificar patrones de comportamiento con considerable precisión (Zhang & Letaief, 2019; Sun et al., 2019). Mao et al. (2018) documentan que las redes neuronales profundas logran una precisión superior al 90% a la hora de predecir los estados de canal dentro de los entornos inalámbricos dinámicos.

b) Detección de fallas: Por otro lado, los sistemas de mantenimiento predictivo que son basados en modelos de clasificación supervisada han permitido identificar anomalías antes de que se conviertan en interrupciones del servicio. Chen et al. (2019) reportan una reducción del tiempo de inactividad entre un 30% y un 45% en operaciones que implementaron estas soluciones.

c) Automatización de operaciones: Finalmente en cuanto a los modelos de aprendizaje automático estos son los que contribuyen a la automatización de tareas repetitivas, como la configuración de parámetros de red y la asignación de recursos espectrales (Jiang et al., 2017; Li et al., 2017).

2. Análisis predictivo en el sector de telecomunicaciones

El análisis predictivo constituye una de las categorías con mayor número de aplicaciones documentadas. Los hallazgos incluyen:

a) Predicción de tráfico de red: El análisis predictivo se ha consolidado como una de las áreas con mayor número de aplicaciones dentro del ecosistema tecnológico contemporáneo. Y no resulta extraño: en un mundo donde cada segundo circula cantidades descomunales de información, la capacidad de anticiparse se ha convertido en una ventaja casi tan valiosa como la propia infraestructura. Los modelos basados en series temporales y redes neuronales recurrentes logran anticipar congestiones en la red con antelación de 15 a 60 minutos, según reportan Li et al. (2017) y Park et al. (2020).

b) Predicción de demanda de servicios: Otro ámbito significativo corresponde a la predicción de demanda de servicios. Sarfraz, Khawaja y Waheed (2025) identifican que las compañías que incorporan técnicas de machine learning para prever las necesidades de los usuarios alcanzan mejoras cercanas al 25 % en la asignación de recursos.

c) Comportamiento de usuarios: Los algoritmos de clustering y clasificación permiten segmentar a los usuarios según patrones de consumo, facilitando la personalización de ofertas (Alrabeiah & Alkhateeb, 2021; Hussain et al., 2020).

Sin embargo, la efectividad de estos modelos depende de la calidad y disponibilidad de los datos históricos, así como de la frecuencia de actualización de los modelos. (Este punto se discutirá en la sección de Discusión).

3. Machine Learning para el fortalecimiento de la ciberseguridad

La literatura revisada evidencia que el Machine Learning desempeña un papel creciente en la protección de infraestructuras de telecomunicaciones. Los principales hallazgos son:

a) Detección de anomalías en tiempo real: Los sistemas basados en aprendizaje no supervisado identifican comportamientos fuera de lo normal en el tráfico de red, con tasas de detección que superan el 95% en entornos controlados (Odeh et al., 2025; Ayoubi et al., 2018).

b) Prevención de intrusiones: Los modelos de clasificación supervisada, entrenados con conjuntos de datos de ataques conocidos, logran identificar intentos de intrusión con una tasa de falsos positivos inferior al 5% (Russell & Norvig, 2021; Alsheikh et al., 2014).

c) Respuesta automatizada a amenazas: Algunos estudios documentan sistemas que combinan ML con reglas automatizadas para aislar nodos comprometidos sin intervención humana (He et al., 2018; Kato et al., 2017).

No obstante, también se identifican riesgos asociados, como los ataques adversariales dirigidos a los propios sistemas de ML, que pueden engañar a los modelos de clasificación (Odeh et al., 2025). (Este punto se discutirá en la sección de Discusión).

4. Infraestructura tecnológica requerida para la adopción de ML

Los estudios revisados coinciden en que la adopción efectiva del Machine Learning requiere una infraestructura tecnológica específica. Los hallazgos incluyen:

a) Capacidad de cómputo: El entrenamiento de modelos profundos requiere unidades de procesamiento gráfico (GPU) o unidades de procesamiento tensorial (TPU). Goodfellow et al. (2016) documentan que un modelo de deep learning típico para procesamiento de señales en redes 5G requiere entre 8 y 32 horas de entrenamiento en hardware especializado.

b) Almacenamiento de datos: Las empresas de telecomunicaciones generan petabytes de datos diariamente. Hien y Tam (2025) reportan que las organizaciones con sistemas de almacenamiento distribuido (como Hadoop o Spark) logran una implementación de ML un 40% más rápida que aquellas con almacenamiento tradicional.

c) Redes de alta velocidad: La transmisión de datos entre nodos de entrenamiento distribuido requiere latencias inferiores a 10 ms, según documentan Wang et al. (2021) y Tang et al. (2020).

En muchas organizaciones, especialmente en contextos en desarrollo, la falta de inversión en estos componentes limita significativamente la adopción de ML. (Este punto se discutirá en la sección de Discusión).

5. Desafíos en la adopción del Machine Learning

La literatura revisada identifica tres categorías principales de desafíos que limitan la implementación del ML en telecomunicaciones:

a) Escasez de talento humano especializado: Múltiples estudios coinciden en que existe una brecha significativa entre la demanda de profesionales con habilidades en ML y la oferta disponible. López y Fernández (2025) reportan que el 68% de las empresas de telecomunicaciones en Latinoamérica consideran la falta de talento como la barrera principal.

b) Resistencia al cambio organizacional: Sarfraz, Khawaja y Waheed (2025) identifican que la adopción de ML se ve obstaculizada por estructuras organizacionales rígidas y culturas empresariales adversas al cambio. El 45% de las organizaciones estudiadas reportaron resistencia activa por parte del personal operativo.

c) Limitaciones en la gestión de datos: Los problemas de calidad, privacidad y seguridad de los datos son recurrentes en la literatura. Alsheikh et al. (2014) documentan que hasta el 30% de los proyectos de ML en telecomunicaciones fracasan debido a datos insuficientes o de mala calidad.

6. Resumen cuantitativo de hallazgos


Tabla 3. Resumen de principales aplicaciones del Machine Learning en telecomunicaciones

Área de aplicación	Descripción del hallazgo	Fuente(s) clave
Optimización de redes	El ML permite identificar patrones de comportamiento en infraestructuras de red y	Zhang & Letaief (2019); Mao et al. (2018)

	predecir estados de canal con alta precisión	
Mantenimiento predictivo	Los sistemas basados en ML diagnostican fallas en redes móviles de manera autónoma, superando a métodos tradicionales	Chen et al. (2019)
Análisis de tráfico	Los modelos de aprendizaje predicen tráfico a nivel de aplicación usando big data de redes celulares	Li et al. (2017)
Ciberseguridad	Los sistemas de IA/ML detectan amenazas en tiempo real y permiten respuestas automatizadas	Odeh et al. (2025)
Gestión de espectro	El deep learning analiza parámetros de red (retardo, SNR) para identificar cuellos de botella y disponibilidad de espectro	Mao et al. (2018)

Fuente: Elaboración propia a partir de la literatura revisada.

Figura 2. Principales áreas de aplicación del Machine Learning en telecomunicaciones



4. Discusión

A continuación, se presenta la discusión de los hallazgos reportados en la sección anterior. Se interpretan los resultados, se contrastan con la literatura existente y se responde a la pregunta de investigación planteada.

1. El Machine Learning como habilitador de la transformación digital

Los resultados evidencian que el Machine Learning contribuye significativamente a la optimización de procesos en el sector de las telecomunicaciones, especialmente en la gestión de redes, la detección de fallas y la automatización de operaciones. Los hallazgos encontrados son coherentes con lo reportado por Zhang y Letaief (2019) y Sun et al. (2019), quienes documentan mejoras significativas en la eficiencia operativa gracias a la implementación de modelos predictivos.

Teniendo en cuenta lo anterior se da a evidenciar que el ML no solo se limita a optimizar los procesos ya existentes, sino que también redefine los procesos mediante los cuales las empresas gestionan sus operaciones, en línea con los objetivos de la transformación digital descritos por Vial (2019). Desde esta perspectiva, el ML permite a las empresas de telecomunicaciones pasar de una gestión reactiva (corregir las fallas después de que ocurren) a una gestión proactiva (prevenir las fallas antes de que ocurran).

Este cambio constituye un cambio de operaciones en las redes, que pasan de una gestión manual a una autónoma basada en datos. Park et al. (2020) nos dice que la inteligencia al borde de la red (Edge intelligence) representa un avance cualitativo en la capacidad de reacción de las infraestructuras de telecomunicaciones.

2. Análisis predictivos como ventaja competitiva

Los resultados demuestran que el análisis predictivo es una de las aplicaciones con mayor potencial del ML, porque permite anticipar fenómenos como las congestiones de red, la demanda de servicios y determinados patrones de comportamiento de los usuarios. Esto coincide con lo documentado por Li et al. (2017), donde se evidenciaron que los modelos de predicción basados en Big Data mejoran la asignación de recursos.

No obstante, la efectividad de estos modelos no esta garantizada. Su desempeño depende de gran manera de la calidad de los datos que se vayan a utilizar, de igual manera en la frecuencia de actualización de los modelos. Esto coincide con lo documentado por Alsheikh et al. (2014) y Goodfellow et al. (2016), quienes destacan la importancia de contar con datos apropiados para conseguir resultados confiables, esta idea suele resumirse en la expresión “garbage in, garbage out” (basura entra, basura sale).

3. Retos y limitaciones en la ciberseguridad

En este campo de la ciberseguridad, los resultados evidencian que el ML fortalece el diagnóstico y la detección de anomalías en comparación a otros procedimientos tradicionales. En este sentido, Odeh et al. (2025) y Ayoubi et al. (2018) señalan que los sistemas que están basados en ML identifican patrones de ataque que algunos sistemas con reglas fijas no pueden detectar. Sin embargo, también se identificaron riesgos asociados a la incorporación de estas técnicas además de implicar nuevos desafíos para la seguridad. Entre ellos se encuentran los ataques adversariales (entradas diseñadas específicamente para engañar a los modelos de ML). Odeh et al.

(2025), señala que en un escenario de ataque como este se podrían modificar de manera sutil el tráfico de la red, esto con el objetivo que el clasificador lo etiquete de manera errónea como benigno.

Como consecuencia, la incorporación del ML en ciberseguridad no debe tomarse como una solución definitiva, debe entenderse como una táctica que, además de ofrecer nuevas capacidades de detección, también introduce desafíos que necesitan mecanismos específicos de protección y supervisión. Para ello, implementar un enfoque híbrido que técnicas de ML con procedimientos tradicionales como frimas, reglas y firewalls.

4. Deficiencia de la infraestructura como impedimento estructural

En los resultados queda en evidencia que la falta de una infraestructura tecnológica apropiada es una barrera determinante para una incorporación adecuada del ML. Hien y Tam (2025) señalan que las organizaciones que no disponen de un sistema de almacenamiento bien distribuido en capacidad de cómputo presenta dificultades para implementar soluciones ML a gran escala.

Esta situación se puede entender como un tipo de brecha digital de segundo orden, dado que las diferencias tecnológicas no solo se limitan al acceso a internet, sino también abarcan la capacidad de las organizaciones para analizar y procesar datos. Como es señalado por CEPAL (2025), esta brecha es más pronunciada en Latinoamérica donde la inversión para la infraestructura tecnológica es menor que en los países desarrollados.

Esta limitación también limita la transformación digital en el sector de las telecomunicaciones, ya que sin una infraestructura adecuada las empresas no pueden aprovechar de manera adecuada los beneficios del ML, lo que los deja en desventaja frente a los operadores internacionales.

5. Retos organizacionales y humanos

Aparte de las limitaciones tecnológicas, los resultados dejan en evidencia los desafíos relacionados con la falta de talento especializado y la resistencia al cambio tecnológico son los factores más significativos encontrados en los documentos revisados.

Sarfraz, Khawaja y Waheed (2025) señalan que a la implementación del ML es más exitosa en las organizaciones que tienen una cultura más digital, donde las personas están abiertas a la experimentación y el aprendizaje tecnológico. Por el contrario, en organizaciones con ideas más rígidas dificultan más la implementación de herramientas tecnológicas.

6. Respuesta a la pregunta de investigación

La pregunta que se planteó al inicio de la investigación del artículo fue:

¿Cómo influye el Machine Learning en la transformación digital del sector de las telecomunicaciones y cuáles son los principales desafíos que limitan su implementación efectiva?

A partir de los resultados obtenidos, se puede establecer que:

- El ML tiene un impacto positivo en la transformación digital de las telecomunicaciones, con un notable efecto en tres ámbitos principales: optimización de procesos operativos, toma de decisiones por medio de análisis predictivo y el fortalecimiento de la ciberseguridad.
- La implementación de manera efectiva del ML se encuentra condicionada por diversos factores como: la falta de infraestructura, la ausencia de la cultura digital y la escasez de profesionales especializados y la resistencia al cambio tecnológico.
- En términos generales el ML se puede considerar un pilar estratégico para la transformación digital, pero hay que tener en cuenta que su éxito no está garantizado, Ya que sus beneficios no dependen únicamente por los algoritmos o modelos incorporados, sino de la capacidad de las empresas o organizaciones para desarrollar las condiciones necesarias para su buena implementación.

7. Coherencia con el estado del arte

Los hallazgos obtenidos durante el desarrollo de este artículo tienen relación con los documentos seleccionados para a investigación. Jordan y Mitchell (2015), en su análisis publicado en Science, señalaban que el éxito de la aplicación del ML depende tanto de los algoritmos como la infraestructura y los sistemas necesarios para su funcionamiento. De igual manera, LeCun, Bengio y Hinton (2015) destacaban que el Deep Learning requiere grandes cantidades de datos y una capacidad de procesamiento significativa para alcanzar resultados adecuados.

Para el contexto específico de las telecomunicaciones, Lataief et al. (2019) y Saad et al. (2020) coinciden en que las futuras redes 6G tendrán incorporadas capacidades IA de manera cada vez más integrada, pero advierten que una transición hacia las redes autónomas dependerá inversiones continuas en la infraestructura y el desarrollo de talento especializado.

Lo que aporta este artículo respecto al estado del arte es la sistematización de los desafíos desde una perspectiva integral (tecnológica, organizacional y humana), así como la contextualización para América Latina, donde la literatura aún es escasa.

5. Conclusiones

1. Resultados clave

A partir de la revisión de literatura realizada, se identificaron los siguientes hallazgos principales:

Primero, el Machine Learning contribuye significativamente a la optimización de procesos en el sector de las telecomunicaciones, especialmente en la gestión de redes (identificación de patrones de comportamiento), el mantenimiento predictivo (detección temprana de fallas) y la automatización de operaciones repetitivas (Zhang & Letaief, 2019; Chen et al., 2019; Mao et al., 2018).

En segundo lugar, el análisis predictivo basado en ML permite anticipar congestiones de red, demandas de servicio y comportamientos de los usuarios, lo que ayuda a mejorar la toma de

decisiones y a utilizar los recursos disponibles de manera más eficiente (Li et al., 2017; Park et al., 2020; Sarfraz et al., 2025).

Tercero, en el ámbito de la ciberseguridad, los sistemas de ML mejoran la detección de anomalías y la prevención de intrusiones en tiempo real, aunque introducen nuevos riesgos como los ataques adversariales (Odeh et al., 2025; Ayoubi et al., 2018).

Cuarto, la adopción efectiva del ML enfrenta desafíos en tres niveles: tecnológico (falta de infraestructura de cómputo y almacenamiento, mala calidad de datos), organizacional (estructuras rígidas, ausencia de cultura digital) y humano (escasez de talento especializado, resistencia al cambio) (Hien & Tam, 2025; López & Fernández, 2025; Sarfraz et al., 2025).

2. Verificación del objetivo

El objetivo general del presente artículo fue analizar el impacto del Machine Learning en la transformación digital del sector de las telecomunicaciones, identificando sus principales aplicaciones y los desafíos asociados a su implementación.

Sí, el objetivo fue alcanzado. A través de la revisión narrativa de literatura, se logró:

Objetivo específico	¿Se alcanzó?	Evidencia
Describir aplicaciones del ML en optimización de procesos, análisis predictivo y ciberseguridad	Sí	Secciones 1, 2 y 3 de Resultados
Identificar barreras tecnológicas, organizacionales y humanas	Sí	Sección 5 de Resultados y sección 5 de Discusión
Sintetizar hallazgos para ofrecer visión integral del estado del arte	Sí	Tabla 3 y sección 6 de Discusión

En consecuencia, el artículo cumple con el propósito planteado en la introducción y responde a la pregunta de investigación formulada.

3. Limitaciones del trabajo

El presente estudio presenta las siguientes limitaciones, que deben tenerse en cuenta al interpretar sus hallazgos:

Limitaciones metodológicas:

La revisión narrativa, a diferencia de una revisión sistemática con protocolo PRISMA, no cuantifica la calidad metodológica de los estudios incluidos ni garantiza la exhaustividad en la búsqueda (Ferrerías-Fernández et al., 2024). Existe el riesgo de sesgo en la selección de fuentes.

El enfoque cualitativo impide generalizar estadísticamente los hallazgos o calcular tamaños de efecto promedio.

Limitaciones de acceso a información:

Algunos artículos de conferencias de alto impacto (IEEE, ACM) requieren membresías o pagos que no estaban disponibles.

Limitaciones de tiempo:

La búsqueda de información se centro en publicaciones entre 2019 y 2025, esto con el propósito de priorizar documentos con información reciente. Sin embargo, también se incluyeron de manera complementaria fuentes anteriores a 2019 si se encontraba con una relevancia necesaria para fundamentar conceptos relacionados con el ML, Deep Learnign, aprendizaje por refuerzo y tecnologías de las telecomunicaciones. En consecuencia, la selección final termino incluyendo algunas referencias anteriores al periodo principal de búsqueda.

4. Trabajos a futuro

Teniendo en cuenta los hallazgos y las limitaciones identificadas, se proponen 4 líneas que podrían ser utilizadas para orientar futuras investigaciones:

Línea 1: Estudios empíricos en Latinoamérica:

Los documentos analizados para el desarrollo de este artículo son estudios dominados principalmente por economías desarrolladas como Estados Unidos, Europa o China. En este sentido, se requieren realizar investigaciones de forma empírica que documenten como es la adopción del ML en empresas de telecomunicaciones de América Latina y Colombia, con el propósito de identificar qué factores podrían favorecer su implementación con éxito en la región.

Línea 2: Desarrollo de marcos de implementación:

Esta segunda línea de investigación podría centrarse en el desarrollo de un marco metodológico que se centre en guiar a las empresas de las telecomunicaciones en los procesos de implementación del ML.

Línea 3: Análisis de costo-beneficio en la adopción del ML:

Esta línea de investigación podría centrarse en realizar estudios a futuros que puedan cuantificar mediante modelos financieros el retorno de la inversión (ROI) al implementar soluciones de ML en diferentes áreas como el análisis de tráfico, mantenimiento predictivo y ciberseguridad, esto con el fin de proporcionar información que contribuya a respaldar la toma de decisiones gerenciales.

Línea 4: El impacto ambiental del ML

Una línea que es poco explorada es como afecta la implementación del ML al medio ambiente, ya que el entrenamiento y la ejecución de modelos complejos requieren grandes cantidades de energía, por lo que en futuras investigaciones se podrían implementar estudios que evalúen el consumo energético y la huella de carbono asociadas con estas tecnologías y se propongan enfoques sostenibles.

Referencias

- Alsheikh, M. A., et al. (2014). Machine learning in wireless sensor networks: Algorithms, strategies, and applications. *IEEE Communications Surveys & Tutorials*, 16(4), 1996–2018.
- Alrabeiah, M., & Alkhateeb, A. (2021). Deep learning for mmWave beam prediction. *IEEE Transactions on Wireless Communications*, 20(6), 3678–3692.
- Ayoubi, S., et al. (2018). Machine learning for cognitive optical networks: A survey. *IEEE Communications Magazine*, 56(1), 158–165.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Bockelmann, C., et al. (2016). Massive machine-type communications in 5G: Physical and MAC-layer solutions. *IEEE Communications Magazine*, 54(9), 59–65.
- Braun, V., & Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative Research in Psychology*, 3(2), 77–101.
- Chen, M., Challita, U., Saad, W., Yin, C., & Debbah, M. (2019). Artificial neural networks-based machine learning for wireless networks: A tutorial. *IEEE Communications Surveys & Tutorials*, 21(4), 3039–3071.
- Chen, S., et al. (2020). Machine learning for wireless networks with artificial intelligence: A survey. *China Communications*, 17(10), 1–4.
- Chowdhury, M. Z., Shahjalal, M., Ahmed, S., & Jang, Y. M. (2020). 6G wireless communication systems: Applications, requirements, technologies, challenges, and research directions. *IEEE Open Journal of the Communications Society*, 1, 957–975.
- Cisco Systems. (2020). *Cisco annual internet report (2018–2023)* [White paper].
- Deng, L., & Yu, D. (2014). Deep learning: Methods and applications. *Foundations and Trends in Signal Processing*, 7(3–4), 197–387.
- Ericsson. (2021). *Mobility report* [Technical report].
- Fortino, G., et al. (2017). BodyCloud: A SaaS approach for community body sensor networks. *Future Generation Computer Systems*, 35, 62–79.
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow* (2nd ed.). O'Reilly Media.

- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Gubbi, J., et al. (2013). Internet of Things (IoT): A vision, architectural elements, and future directions. *Future Generation Computer Systems*, 29(7), 1645–1660.
- Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson Education.
- He, Y., et al. (2018). Deep reinforcement learning-based optimization for cache-enabled opportunistic interference alignment wireless networks. *IEEE Transactions on Vehicular Technology*, 66(11), 10433–10445.
- Hinton, G., et al. (2012). Deep neural networks for acoustic modeling in speech recognition. *IEEE Signal Processing Magazine*, 29(6), 82–97.
- Hussain, R., et al. (2020). Machine learning for next-generation intelligent transportation systems: A survey. *IEEE Communications Magazine*, 58(1), 44–51.
- International Telecommunication Union. (2020). *Machine learning in future networks including 5G* [Technical report].
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260.
- Kato, N., et al. (2017). The deep learning vision for heterogeneous network traffic control: Proposal, challenges, and future perspective. *IEEE Network*, 31(2), 4–11.
- Kelleher, J. D., Mac Namee, B., & D'Arcy, A. (2020). *Fundamentals of machine learning for predictive data analytics* (2nd ed.). MIT Press.
- Krizhevsky, A., Sutskever, I., & Hinton, G. (2012). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Letaief, K. B., et al. (2019). The roadmap to 6G: AI as a key enabler. *IEEE Communications Magazine*, 57(8), 84–90.
- Li, R., Zhao, Z., Zhou, X., Palicot, J., & Zhang, H. (2017). The prediction analysis of cellular radio access network traffic: From entropy theory to machine learning. *IEEE Transactions on Cognitive Communications and Networking*, 3(1), 50–58.
- Luong, N. C., et al. (2019). Applications of deep reinforcement learning in communications and networking: A survey. *IEEE Communications Surveys & Tutorials*, 21(4), 3133–3174.
- Mao, Q., Hu, F., & Hao, Q. (2018). Deep learning for intelligent wireless networks: A comprehensive survey. *IEEE Communications Surveys & Tutorials*, 20(4), 2595–2621.

McMahan, B., et al. (2017). Communication-efficient learning of deep networks from decentralized data. In *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics* (pp. 1273–1282).

Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.

Murphy, K. P. (2012). *Machine learning: A probabilistic perspective*. MIT Press.

Osman, A., et al. (2020). Machine learning techniques in wireless sensor networks: A survey. *IEEE Access*, 8, 180593–180609.

Park, J., Samarakoon, S., Bennis, M., & Debbah, M. (2020). Wireless network intelligence at the edge. *Proceedings of the IEEE*, 107(11), 2204–2239.

Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.

Saad, W., Bennis, M., & Chen, M. (2020). A vision of 6G wireless systems: Applications, trends, technologies, and open research problems. *IEEE Network*, 34(3), 134–142.

Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117.

Shafi, M., et al. (2017). 5G: A tutorial overview of standards, trials, challenges, deployment, and practice. *IEEE Journal on Selected Areas in Communications*, 35(6), 1201–1221.

Silver, D., et al. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587), 484–489.

Sun, Y., Peng, M., Zhou, Y., Huang, Y., & Mao, S. (2019). Application of machine learning in wireless networks: Key techniques and open issues. *IEEE Communications Magazine*, 57(1), 134–140.

Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction* (2nd ed.). MIT Press.

Tang, F., et al. (2020). AI-empowered edge computing and networking: A survey. *IEEE Network*, 34(3), 4–6.

Vial, G. (2019). Understanding digital transformation: A review and a research agenda. *The Journal of Strategic Information Systems*, 28(2), 118–144.

Wang, J., et al. (2021). Edge AI for 6G networks: Convergence of edge computing and artificial intelligence. *IEEE Wireless Communications*, 28(2), 12–19.

Wang, S., et al. (2017). Dynamic service placement for mobile micro-clouds with predicted future costs. *IEEE Transactions on Parallel and Distributed Systems*, 28(4), 1002–1016.

Wang, C.-X., et al. (2020). Artificial intelligence enabled wireless networking for 5G and beyond: Recent advances and future challenges. *IEEE Wireless Communications*, 27(1), 16–23.

Yu, H., et al. (2020). Federated learning in wireless networks: A survey. *IEEE Communications Surveys & Tutorials*, 22(3), 2031–2063.

Zhang, C., Patras, P., & Haddadi, H. (2019). Deep learning in mobile and wireless networking: A survey. *IEEE Communications Surveys & Tutorials*, 21(3), 2224–2287.

Zhang, Y., & Letaief, K. B. (2019). Machine learning in wireless networks: A tutorial. *IEEE Communications Surveys & Tutorials*, 21(4), 3039–3071.

Banco Interamericano de Desarrollo. (2025). *Estado de la adopción de inteligencia artificial en América Latina* [Informe técnico].

Comisión Económica para América Latina y el Caribe. (2025). *Brechas digitales y transformación tecnológica en América Latina* [Informe técnico].

García-Peñalvo, F. J., & Ramírez-Montoya, M. S. (2024). Digital transformation in Latin American organizations: Challenges and opportunities. *Comunicar*, 32(78), 45–58.

Hien, L. T., & Tam, P. T. (2025). Digital infrastructure and its role in economic development. *Emerging Science Journal*.

López, J. C., & Fernández, M. (2025). Barreras para la adopción de machine learning en pymes de telecomunicaciones en Colombia. *Revista Latinoamericana de Ingeniería de Sistemas*, 17(1), 23–41.

Sarfraz, M., Khawaja, K. F., & Waheed, Z. (2025). The role of big data and machine learning in business process innovation. *Business Process Management Journal*.

Unión Internacional de Telecomunicaciones. (2024). *Informe de digitalización global 2024* [Informe técnico].

3GPP. (2021). *Study on artificial intelligence (AI)/machine learning (ML) for NR air interface* (TR 38.844).

Odeh, A., Salameh, W., Abu Taleb, A., Abu Al-Haija, Q. S., & Alhajjah, T. (2025). Artificial intelligence in cybersecurity: Trends and applications. In *Studies in computational intelligence*. Springer.