



**FACULTAD DE CIENCIAS E INGENIERÍA
PROGRAMA ACADÉMICO DE INGENIERÍA DE
SISTEMAS DE INFORMACIÓN**

TESIS

**“MEJORA DEL RENDIMIENTO DE REDES DE
TELECOMUNICACIONES MEDIANTE TÉCNICAS DE
INTELIGENCIA ARTIFICIAL EN LA CIUDAD DE NAUTA,
2025”**

**PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO DE
SISTEMAS DE INFORMACIÓN**

AUTOR:

Bach. ARONES TUESTA, EDU ANDRÉ

ASESOR:

ING. ANGEL ALBERTO MARTHANS RUIZ, Mtro.

ORCID 0000-0003-3045-6423

A handwritten signature in blue ink, likely belonging to the advisor, Angel Alberto Marthans Ruiz, is positioned to the right of the ORCID number.

REGIÓN LORETO, PERÚ

2025

ACTA DE SUSTENTACIÓN

Con Resolución Decanal N° 420-2023-UCP-FCEI, del 15 de junio del 2023, se designó jurado.

Con Resolución Decanal N° 333-2026-UCP-FCEI, del 21 de abril del 2026, se autorizó la sustentación.

Siendo las 10:00 a.m. del día 28 de abril del 2026, se constituyó de modo presencial el Jurado para escuchar la presentación y defensa de la Tesis: **"MEJORA DEL RENDIMIENTO DE REDES DE TELECOMUNICACIONES MEDIANTE TÉCNICAS DE INTELIGENCIA ARTIFICIAL EN LA CIUDAD DE NAUTA, 2025"**.

Presentado por:

EDU ANDRE ARONES TUESTA

Para optar el título profesional de Ingeniero de Sistemas de Información


Asesor: Ing. ÁNGEL ALBERTO MARTHANS RUÍZ, Mg.


Luego de escuchar la sustentación y defensa ante las preguntas, el Jurado pasó a la deliberación en forma reservada, llegando a la siguiente conclusión:

La sustentación es: Aprobado por Mayoría

A las 11:16 horas culminó el acto público.

En fe de lo cual los miembros del jurado firman el Acta y comunican en acto público.


Ing. Jimmy Max Ramirez Villacorta, Dr.
Presidente del Jurado


Lic. Carlos Enrique Marthans Ruiz, Mg.
Miembro del jurado


Ing. Tonny Eduardo Bardales Lozano, Mg.
Miembro del jurado



“Año de la Esperanza y el Fortalecimiento de la Democracia”

**CONSTANCIA DE ORIGINALIDAD DEL TRABAJO DE INVESTIGACIÓN
DE LA UNIVERSIDAD CIENTÍFICA DEL PERÚ – UCP**

El presidente del Comité de Ética e Integridad Científica

Hace constar que:

La Tesis titulada:

**“MEJORA DEL RENDIMIENTO DE REDES DE TELECOMUNICACIONES
MEDIANTE TÉCNICAS DE INTELIGENCIA ARTIFICIAL EN LA CIUDAD
DE NAUTA, 2025”**

Del alumno: **EDU ANDRÉ ARONES TUESTA**, de la Facultad de Ciencias e Ingeniería, pasó satisfactoriamente la revisión por el Software Antiplagio, con un porcentaje de **13% de similitud**. Se expide la presente, a solicitud de la parte interesada para los fines que estime conveniente.

San Juan, 10 de abril del 2026.

A handwritten signature in blue ink, appearing to read 'Jorge L. Tapullima Flores', is written over a horizontal line.

**Presidente del Comité de Ética e
Integridad Científica
Mgr. Arq. Jorge L. Tapullima Flores**



UCP_Ingenieria de Sistemas de Informacion_2026_tesis(Edu_Arones_V1_resumen)

ID : 841aa1a2396e4b1c42bbed157bc6951888c52f4c



13%
Textos
sospechosos

Nombre del fichero : UCP_Ingenieria de Sistemas de
Informacion_2026_tesis(Edu_Arones_V1_resumen).txt
Tamaño del archivo original : 506,4 kB
Número de palabras : 15.825
Número de caracteres : 107207

Depositante : Chris Angela Ramirez Flores
Fecha de depósito : 9 de abril de 2026
Tipo de carga : interface
fecha de fin de análisis : 9 de abril de 2026

Resumen (sección 1/3)

Localización de los textos sospechosos en el documento :



Incluido en el porcentaje de textos sospechosos :



Similitudes

<1%

Sintáctica <1%

Semántica No medido

Pasajes con similitudes a fuentes encontradas en diferentes colecciones.



Detección de IA

10%

Textos estilísticamente próximos a un texto generado por una IA.

Este índice es un indicador y no una prueba. Comprueba con el autor si domina los conocimientos mencionados en el documento.



Idiomas no reconocidos

3%

Pasajes en los que parte del vocabulario utilizado no forma parte del diccionario de la lengua. Puede tratarse de un intento del autor de modificar el texto para evitar ser detectado.





HOJA DE APROBACIÓN

PROGRAMA ACADÉMICO DE INGENIERÍA DE SISTEMAS DE INFORMACIÓN

BACHILLER: EDU ANDRE ARONES TUESTA

**La Tesis sustentada en acto público el día 28 de abril del 2026, a las 10:00 am,
en las instalaciones de la UNIVERSIDAD CIENTÍFICA DEL PERÚ.**

A blue ink signature of Ing. Jimmy Max Ramirez Villacorta, consisting of a large, stylized 'J' and 'M'.

**ING. JIMMY MAX RAMIREZ VILLACORTA, DR
PRESIDENTE DE JURADO**

A blue ink signature of Lic. Carlos Enrique Marthans Ruiz, featuring a large, stylized 'C' and 'M'.

**LIC. CARLOS ENRIQUE MARTHANS RUIZ, MTRO.
MIEMBRO DE JURADO**

A blue ink signature of Ing. Tonny Eduardo Bardales Lozano, featuring a large, stylized 'T' and 'B'.

**ING. TONNY EDUARDO BARDALES LOZANO, MG.
MIEMBRO DE JURADO**

A blue ink signature of Ing. Ángel Alberto Marthans Ruiz, featuring a large, stylized 'A' and 'M'.

**ING. ÁNGEL ALBERTO MARTHANS RUÍZ, MG.
ASESOR**

Dedicatoria

Dedico este trabajo a mi familia, por acompañarme con paciencia y confianza en cada etapa, incluso cuando el cansancio y la presión académica se hicieron más fuertes. Dedico también este esfuerzo a la ciudad de Nauta, porque sus necesidades reales de conectividad dieron sentido al tema investigado y me motivaron a buscar una propuesta útil y aplicable.

Agradecimiento

Agradezco a Dios por darme fortaleza y claridad para culminar este trabajo. De igual modo, agradezco a mis padres por su apoyo incondicional, por sus consejos y por sostenerme con amor y paciencia durante todo el proceso.

ÍNDICE DE CONTENIDO

Dedicatoria	02
Agradecimiento	03
Página de aprobación	04
Resumen	08
Abstract	09
Introducción	10
CAPÍTULO I. MARCO TEÓRICO	11
1.1 Antecedentes del estudio	11
1.1.1 Internacionales	11
1.1.2 Nacionales	13
1.2 Bases teóricas	14
1.2.1 Redes de telecomunicaciones	14
1.2.2 Inteligencia artificial	17
1.2.3 Aprendizaje automático	21
1.2.4 Optimización de redes	26
1.3 Definición de términos básicos	30
1.3.1 Transferencias de datos	30
1.3.2 Sistemas inteligentes	30
1.3.3 Algoritmos y modelos	30
1.3.4 Datos y experiencia	31
1.3.5 Algoritmos y métodos de optimización	31
CAPÍTULO II. PLANTEAMIENTO DEL PROBLEMA	32
2.1 Descripción del problema	32
2.2 Formulación del problema	33
2.2.1 Problema general	33
2.2.2 Problemas específicos	33
2.3 Objetivos	34
2.3.1 Objetivo general	34
2.3.2 Objetivos específicos	34
2.4 Justificación de la investigación	34
2.5 Hipótesis	36
2.5.1 Hipótesis General	36
2.5.2 Hipótesis Específicas	36
2.6 Variables	37
2.6.1 Identificación de variables	37
2.6.2 Definición de las variables	37
2.6.3 Operacionalización de las variables	39
CAPÍTULO III. METODOLOGÍA	40
3.1 Tipo y diseño de investigación	40
3.1.1 Tipo de investigación	40
3.1.2 Diseño de investigación	40
3.2 Población y muestra	41

3.2.1	Población	41
3.2.2	Muestra	41
3.3	Técnicas, instrumentos y procedimientos de recolección de datos	42
3.3.1	Técnicas de recolección de datos	42
3.3.2	Instrumentos de recolección de datos	42
3.3.3	Procedimientos de recolección de datos	43
3.4	Procesamiento y análisis de datos	44
3.4.1	Procesamiento de los datos	44
3.4.2	Análisis de los datos	44
3.5	Selección y justificación del algoritmo de AA	45
3.6	Diseño de la implementación al modelo	46
3.6.1	Procesamiento de datos	46
3.6.2	Arquitectura del modelo	46
3.6.3	Entrenamiento y validación	48
3.6.4	Lógica de mitigación proactiva	49
	CAPÍTULO IV. RESULTADOS	55
4.1	Resultados	50
4.1.1	Resultados del Objetivo específico 01	50
4.1.2	Resultados del Objetivo específico 02	51
4.1.3	Resultado del Objetivo específico 03	52
4.1.4	Resultados de la hipótesis general	54
	CAPÍTULO V. DISCUSIÓN, CONCLUSIONES Y RECOMENDACIONES	55
5.1	Discusión	55
5.2	Conclusiones	56
5.3	Recomendaciones	57
	REFERENCIAS BIBLIOGRÁFICAS	58
	ANEXOS	61
	Anexo 01: Matriz de consistencia	62

ÍNDICE DE TABLAS

Tabla 01: Desafíos éticos del aprendizaje automático	24
Tabla 02: Desafíos técnicos del aprendizaje automático	25
Tabla 03: Operacionalización de variables	39
Tabla 04: Arquitectura del modelo	46
Tabla 05: Resultados de la validación	48
Tabla 06: Resumen de hiperparámetros	49
Tabla 07: Estadísticos descriptivos del pre test de la red	50
Tabla 08: Estadísticos descriptivos del pos test de la red	50
Tabla 09: Métricas de validación del modelo Random Forest	51
Tabla 10: Matriz de confusión del modelo Random Forest	52
Tabla 11: Comparación de indicadores pretest y posttest	52
Tabla 12: Prueba de normalidad de los indicadores de red	53
Tabla 13: Prueba de Wilcoxon para comparación pretest y posttest	53
Tabla 14: Resumen general de mejora del rendimiento de red	54

RESUMEN

El trabajo de investigación titulado “MEJORA DEL RENDIMIENTO DE REDES DE TELECOMUNICACIONES MEDIANTE TÉCNICAS DE INTELIGENCIA ARTIFICIAL EN LA CIUDAD DE NAUTA, 2025”, tuvo como objetivo general determinar la mejora del rendimiento de la red mediante la aplicación de aprendizaje automático, orientado a predecir la congestión y apoyar las decisiones de optimización. El estudio se desarrolló con enfoque cuantitativo, tipo aplicado y diseño preexperimental con medición pretest y posttest, comparando el comportamiento de la red antes y después de la intervención. Para esta investigación, los registros de rendimiento de la red sirvieron como población de análisis, concentrándose la evaluación en tres indicadores de calidad de servicio, como son latencia, ancho de banda y pérdida de paquetes. En el procesamiento de datos, se tomaron en cuenta los procedimientos de limpieza y preparación de datos, con su respectivo análisis estadístico e inferencial. La validación técnica del modelo Random Forest tuvo un desempeño predictivo elevado, mostrando una exactitud de 91,4% y un índice Kappa de 0,82, que son resultados que reflejan una concordancia alta entre las predicciones y los eventos que se observaron. La diferencia entre el pretest y el posttest mostró mejoras que fueron estadísticamente significativas en los indicadores seleccionados. Se redujo la latencia en 59,5 ms y el ancho de banda se incrementó en 3,71 mbps, mientras que la pérdida de paquetes disminuyó en 3,26%. Dichos cambios se relacionan con un comportamiento más estable y eficiente en los periodos de mayor demanda. Con estos hallazgos, queda demostrado que la implementación de aprendizaje automático anticipa una gestión más favorable del rendimiento, mejora la calidad del servicio así como la confiabilidad operativa de la red en la ciudad de Nauta.

Palabras clave: aprendizaje automático, Random Forest, QoS, congestión de red, telecomunicaciones.

ABSTRACT

The research entitled “IMPROVING TELECOMMUNICATIONS NETWORK PERFORMANCE THROUGH ARTIFICIAL INTELLIGENCE TECHNIQUES IN THE CITY OF NAUTA, 2025” aimed to determine whether machine learning can enhance network performance by predicting congestion and supporting optimization decisions. A quantitative, applied approach was adopted under a pre-experimental design with pre-test and post-test measurements, comparing network behavior before and after the intervention. The analytical population comprised network performance records, and the evaluation focused on three QoS indicators: latency, bandwidth, and packet loss. Data preparation included cleaning and standardization procedures, followed by descriptive and inferential statistical analysis to test the study hypothesis. The Random Forest model achieved strong predictive performance, reaching 91.4% accuracy and a Cohen’s Kappa of 0.82, indicating high agreement between predictions and observed traffic events. The pre-test versus post-test comparison reported statistically significant improvements across all key indicators: average latency decreased by 59.50 ms, effective bandwidth increased by 3.71 Mbps, and packet loss dropped by 3.26%, reflecting greater stability and efficiency during high-demand periods. Overall, the findings confirm that integrating machine learning enables a more proactive operational approach, improves service quality, and strengthens network reliability for users in Nauta.

Keywords: *Machine learning, Random Forest, QoS, Network congestion, telecommunications.*

INTRODUCCIÓN

La transformación tecnológica contemporánea ha modificado la manera en que las organizaciones y los territorios se comunican, gestionan sus procesos y ofrecen servicios a la ciudadanía. En ese contexto, la inteligencia artificial se ha convertido en una herramienta estratégica para optimizar sistemas complejos, incluyendo las redes de telecomunicaciones que sostienen la conectividad digital. Las ciudades ubicadas en la Amazonía del Perú, como Nauta por ejemplo, enfrentan una situación vulnerable debido a la débil infraestructura que poseen, mientras la demanda de tráfico muestra un crecimiento sostenido. Tales características, hacen que la saturación aumente y se pierda la calidad en la transmisión de datos. Para solucionar este inconveniente, se requiere modernizar la infraestructura tecnológica y mejorar la gestión para que sea capaz de anticiparse a los problemas a fin de lograr eficiencia en el comportamiento de la red.

En la actualidad, el aprendizaje automático permite anticipar comportamientos de red, detectar anomalías y ajustar los parámetros de operación antes de que se produzca la congestión. Son capacidades que representan una oportunidad concreta para elevar la calidad del servicio, en contextos donde los recursos técnicos y financieros son escasos. De igual modo, la integración de modelos predictivos en la gestión de redes, permite reducir tiempos de inactividad, incrementar la eficiencia y mejorar la experiencia de los usuarios finales.

Con esta investigación se analiza la ayuda que puede hacer el aprendizaje automático, para mejorar la red de telecomunicaciones en la ciudad de Nauta, partiendo de la idea que un modelo predictivo bien entrenado, puede anticipar problemas de congestión y ayudar a mejorar el funcionamiento del servicio, con mejores tiempos en las respuestas, mayor capacidad para la transmisión de datos y una cantidad menor de pérdidas durante la conexión. El estudio busca realizar aportes al desarrollo tecnológico de la región amazónica, que presenta muchas limitaciones en su conectividad.

CAPÍTULO I

MARCO TEÓRICO

1.1. ANTECEDENTES DEL ESTUDIO

1.1.1. Internacionales

Según (CORDERO-PÉREZ, y otros, 2024), en su artículo "Inteligencia Artificial en la Gestión de Redes Telemáticas: Avances, Tendencias y Aplicaciones Actuales", se analiza cómo la IA está revolucionando la gestión de redes a través de la automatización y la optimización del rendimiento. El estudio presenta un caso práctico de optimización en una empresa global de telecomunicaciones, que implementó modelos de Machine Learning para el análisis de tráfico y la detección de patrones. Los resultados cuantitativos demuestran la efectividad de la solución, reportando una reducción de los tiempos de inactividad en un 30% y una mejora de la calidad del servicio en un 25% después de la implementación de la IA. El estudio concluye que el mantenimiento predictivo y la optimización impulsada por la IA son esenciales para reducir los costos operativos, mejorar la eficiencia y anticipar problemas en la infraestructura de red.

Según (RIVERA, 2023), en el artículo "Análisis del rendimiento de redes 5G utilizando *machine learning*", publicado en la Revista Vínculos de Colombia, el aprendizaje automático (ML) permite analizar el desempeño de las redes móviles y apoyar su mejora mediante la identificación anticipada de patrones asociados con la congestión y con la latencia. La metodología de investigación se basa en la aplicación de modelos de ML en Python utilizando librerías como Scikit-learn y TensorFlow, sobre métricas de rendimiento como la velocidad de transferencia de datos, la latencia y la tasa de pérdida de paquetes. La investigación concluye que el ML es una herramienta poderosa para el análisis predictivo y la optimización de la red,

permitiendo la asignación eficiente de recursos y la mejora de la confiabilidad, lo cual sienta las bases para gestionar la complejidad inherente de las redes modernas de telecomunicaciones.

Según (ORDOÑEZ, 2021), en su investigación sobre “OPTIMIZACIÓN DE REDES UMTS SOPORTADA EN MACHINE LEARNING”, realizada en Bogotá, Colombia; a los operadores de telefonía celular y sus procesos de optimización de la red dentro del ciclo de optimización de la fase de diagnóstico de las celdas, para lo cual son indispensables los KPIs asociados a contadores estadísticos. El análisis de los KPI se realizó de manera manual con apoyo de la inteligencia artificial, con el fin de clasificar el estado de las celdas UMTS y determinar si corresponde un plan de acción. Los resultados mostraron cambios en la velocidad de entrenamiento cuando se redujo el número de clases por modelo, además, se observó que la cantidad de categorías influye más en el tiempo de entrenamiento que el volumen de registros. La limitada disponibilidad de elementos en una clase puede afectar de forma marcada la sensibilidad y la precisión. En el caso de la clasificación de las celdas UMTS, los diagnósticos presentaron un desempeño adecuado y podrían agilizar los procesos de diagnóstico y de validación en la operación de la red.

Según (RAMOS, 2021), en su investigación sobre “PREDICCIÓN DEL COMPORTAMIENTO DE SLA EN REDES 5G UTILIZANDO INTELIGENCIA ARTIFICIAL”, realizada en Baja California, México, a los operadores de red móvil 5G, que se ven afectados por la aplicación de los acuerdos a nivel de servicio - SLA, según los requisitos del cliente. Se aplicó un marco de gestión para mapear los requisitos de los usuarios a los recursos de la red. Asimismo, la propuesta evaluó la predicción del throughput y reportó el mejor desempeño con una arquitectura neuronal mixta CNN-RNN. De igual forma, la predicción del VHO se ejecutó con resultados satisfactorios, con el mejor

rendimiento asociado con la red neuronal RNN-E1D1. En consecuencia, la combinación de la predicción del *throughput* con la del VHO se planteó como un insumo útil para anticipar escenarios de alta movilidad y reducir el riesgo de incumplimientos de los SLA. De esta manera, se cumplió el objetivo propuesto planteado por el autor.

1.1.2. Nacionales

Según (GUTIERREZ BELTRÁN, y otros, 2025), en su investigación de tesis titulado "Machine learning con boosting sobre la percepción del servicio de internet en Perú", se propone un metamodelo de Aprendizaje Automático (boosting con modelos como XGBoost y LightGBM) para clasificar los patrones de calidad percibida de servicio de Internet residencial en Perú. El estudio preprocesa una gran cantidad de registros (más de 129,000) utilizando variables relacionadas con satisfacción, calidad, demora y servicio al cliente.

Sus resultados mostraron mejoras importantes luego de la aplicación del modelo y, como corolario, se presentaron recomendaciones dirigidas a los operadores de telecomunicaciones para optimizar la infraestructura y disminuir la brecha que se presenta en el Perú.

Según (LINARES, 2022), en su proyecto de investigación para la Universidad Peruana de Ciencias Aplicadas (Lima, Perú), se propone un sistema de optimización para la red celular 4G LTE en la región de Iquitos. El estudio se centra en el diseño de modelos de Machine Learning (ML) para predecir el desempeño de la red utilizando KPIs como el DL/UL Throughput (Ancho de Banda), la posición de las estaciones base y la congestión. La metodología busca estimar el rendimiento de un sistema propuesto con ML y compararlo con la configuración actual de la red. Linares concluye que los modelos de ML son fundamentales para determinar los parámetros óptimos de la red y, en consecuencia, mejorar la calidad de servicio (QoS),

sentando un precedente directo sobre la aplicación de la IA/ML para la optimización de infraestructura en la Amazonía peruana.

1.2. BASES TEÓRICAS

1.2.1. Redes de telecomunicaciones

Una red de telecomunicaciones es un conjunto de dispositivos interconectados que se utilizan para transmitir datos, voz y video entre usuarios finales. Dichas redes pueden abarcar áreas locales o extensas y permiten la comunicación eficiente y confiable entre múltiples dispositivos y aplicaciones. (PETERSON, y otros, 2012).

Una red de telecomunicaciones constituye una estructura interconectada de equipos, enlaces y protocolos que permite la transferencia de información entre diferentes dispositivos de comunicación. La referida red se utiliza para facilitar la transmisión de datos, voz y video, permitiendo una comunicación efectiva y el intercambio de recursos entre los usuarios de la red. (FOROUZAN, 2013).

Las redes de telecomunicaciones son sistemas de infraestructura que permiten la transferencia de información y la comunicación entre dispositivos y usuarios, que se basan en tecnologías y protocolos específicos para permitir la transmisión de datos, voz y video a través de medios de comunicación físicos o inalámbricos, facilitando la colaboración y el intercambio de información en todo el mundo. (GOLENIEWSKI, y otros, 2013).

Las redes de telecomunicaciones se refieren a un conjunto de dispositivos interconectados que permiten la transferencia eficiente y confiable de datos, voz y video entre usuarios finales. Abarcan tanto áreas locales como extensas y desempeñan un papel fundamental en la facilitación de la comunicación y el intercambio de información en todo el mundo.

Por otro lado, se puede afirmar que las redes de telecomunicaciones se sustentan en una infraestructura formada por cables, enlaces inalámbricos, equipos de conmutación, routers y otros dispositivos de red, mediante lo cual se aseguran el transporte y el enrutamiento de la información. La arquitectura de la red puede operar con tecnologías como Ethernet, las redes de área amplia (WAN), las redes de área local (LAN) y las redes inalámbricas, incluyendo Wi-Fi, 4G y 5G. De igual forma, la interoperabilidad depende del uso de protocolos de comunicación estándar, entre ellos TCP/IP, que permiten que los equipos de distintos fabricantes intercambien sus datos con reglas comunes.

¿Para qué sirven las redes de telecomunicaciones?

Sirven para los siguientes procesos:

- Comunicación de voz: Ya que permiten realizar llamadas telefónicas y videollamadas a través de infraestructuras de voz sobre IP (VoIP) y servicios de telefonía tradicionales.
- Transferencia de datos: Las redes de telecomunicaciones posibilitan la transmisión de datos en forma de archivos, correos electrónicos, navegación por Internet y acceso a recursos compartidos.
- Transmisión de video: Tales redes hacen posible la transmisión de contenido multimedia en tiempo real, como streaming de videos, videoconferencias y servicios de televisión a través del Internet también llamado IPTV.

¿Cuáles son las características de las redes de telecomunicaciones?

Las redes de telecomunicaciones presentan determinadas características, que permiten sostener un servicio eficiente y estable. Entre ellas se encuentra la escalabilidad, que está entendida como la

capacidad de la red para ampliarse y adaptarse al incremento de usuarios, dispositivos y volúmenes de tráfico, sin que el rendimiento se deteriore de manera relevante. También destaca la fiabilidad, ya que una red bien diseñada debe mantenerse disponible de forma continua y reducir al mínimo las interrupciones del servicio. De igual manera, la velocidad y el ancho de banda resultan fundamentales, porque determinan la rapidez con la que se transfieren los datos y la capacidad de la red para atender las exigencias de la transmisión de información. La seguridad, por su parte, comprende las medidas orientadas a proteger los datos y la privacidad de los usuarios, mediante mecanismos como el cifrado, la autenticación y el control de acceso.

Ventajas de las redes de telecomunicaciones:

Una de las mayores ventajas está en que acercan a las personas sin importar la distancia, porque permiten hablar, compartir datos y trabajar con otros en cuestión de segundos, aun cuando se encuentren en distintos lugares del mundo. También favorecen un trabajo más ordenado y rápido, ya que facilitan la coordinación entre personas, el intercambio inmediato de información y una respuesta más ágil dentro de las organizaciones o de cualquier equipo que necesite actuar en tiempo real.

Otro beneficio importante consiste en que abren la puerta a una gran cantidad de recursos digitales, debido a que por medio de la red se puede acceder a información, plataformas y servicios de uso diario, como el correo electrónico, la banca virtual, las redes sociales y las compras en línea.

También tenemos la facilidad para poder conectarse desde diferentes dispositivos, siempre que haya buena cobertura y capacidad.

humana. Gracias a ello, hoy existen traductores automáticos, asistentes de voz, chatbots y otras herramientas capaces de conversar con las personas de manera más natural.

En el análisis de imágenes y videos: Permite identificar rostros, ubicar objetos, separar elementos dentro de una imagen y apoyar la lectura de exámenes clínicos. Por esa razón, su presencia es cada vez mayor en la seguridad, en la industria y también en el campo de la salud.

En robótica: Se utiliza en el diseño y control de máquinas, para que puedan realizar movimientos, responder al entorno y dotar de autonomía a sus tareas. Así los robots se adaptan a las situaciones que se les presenten.

En los procesos de automatización: Ordena actividades, reducir tiempos y mejorar decisiones dentro de distintos sectores. Por ello, se aplica en la logística, en la cadena de suministro, en la planificación empresarial y en muchas operaciones donde se necesita más rapidez y mejor control.

En la medicina: Sirve para el apoyo en el diagnóstico, el seguimiento de las historias clínicas, la atención virtual de pacientes y en la investigación para la búsqueda de nuevos medicamentos.

Características esenciales en la inteligencia artificial

Aprendizaje automático: Los sistemas pueden aprender a partir de la recopilación de datos, para mejorar la eficiencia y funcionamiento y así no necesitar recibir instrucciones todo el tiempo, sino funcionar de acuerdo a patrones y resultados.

Razonamiento y toma de decisiones: Con la IA se pretende imitar a la capacidad humana en cuanto a razonamiento y toma de decisiones mediante reglas lógicas, modelos probabilísticos o algoritmos de aprendizaje.

Percepción y comprensión: Con la ayuda de la inteligencia artificial, es posible realizar interpretaciones del entorno mediante sensores y datos, haciendo posible el análisis de información visual, auditiva y textual.

Adaptabilidad y flexibilidad: Los sistemas de IA tienen la capacidad de ajustar su comportamiento ante situaciones volátiles o cambiantes, de aprender de nuevos escenarios y así mejorar su rendimiento con el tiempo.

Ventajas de la inteligencia artificial

Automatización y eficiencia: Porque la IA automatiza tareas repetitivas, incrementando de esta forma la eficiencia, la productividad y el ahorro de costos en distintos sectores.

Toma de decisiones precisas: Con el apoyo de la inteligencia artificial, se pueden analizar grandes volúmenes de datos, para ofrecer recomendaciones y mejorar la eficiencia en la toma de decisiones.

Mejora de la experiencia del usuario: Debido a su diversidad de usos, como en asistentes virtuales, reconocimiento facial y de voz, hace fluida la interacción y utilidad para los usuarios.

Aportes en la investigación y la ciencia: Gracias a su gran capacidad para resolver problemas de alta complejidad, automatizar procesos y realizar búsquedas instantáneas, aporta de manera sustancial a casi todos los campos de la ciencia.

La IA se ha convertido en una herramienta útil y de gran uso por las personas y las organizaciones, porque presenta grandes oportunidades para la investigación, las prácticas de la vida diaria y el funcionamiento administrativo. Sin embargo, este uso pone en debate los dilemas éticos debido al uso de información personal o confidencial. En esta investigación, se han abordado 3 ejes de discusión, que son la

protección de datos personales, la equidad en el acceso y la responsabilidad en la toma de decisiones que están automatizadas.

Privacidad de los datos

Debido a que la inteligencia artificial trabaja con un gran volumen de datos, la información personal se muestra sensible durante sus fases de recolección, almacenamiento y procesamiento. Por esta razón, trabajar sin una autorización válida, información detallada a las personas o sin un consentimiento previo, puede vulnerar su privacidad y seguridad.

Ante ese riesgo, la respuesta tiene que buscarse dentro del ámbito legal, para robustecer los criterios éticos que establezcan límites al accionar de la IA, con la finalidad de garantizar la seguridad de todos.

La equidad en el acceso a las tecnologías de IA

En el campo de la tecnología, se muestran desigualdades en el acceso a la infraestructura y a la conexión. Es una brecha que excluye a determinados grupos y territorios, reduciendo sus posibilidades de acceso y disfrute de los beneficios, trayendo como consecuencia más falta de oportunidad o la ampliación de las distancias socioeconómicas. Pero esta desigualdad, no se produce únicamente en el acceso, puesto que el diseño y entrenamiento de modelos pueden producir algoritmos sesgados, que traigan como consecuencia una discriminación en ámbitos como el empleo, educación o servicios públicos.

Para paliar esta situación se requiere una gran inversión en infraestructura tecnológica y en capacitación constante hacia la población, que masifiquen el uso de la IA y el aprovechamiento de sus beneficios, pero con responsabilidad ética.

Responsabilidad en la toma de decisiones automatizadas

El creciente uso de inteligencia artificial en la toma de decisiones, plantea interrogantes sobre la responsabilidad y la transparencia en este proceso, especialmente en los campos de la justicia, salud y economía. Aún los algoritmos presentan limitaciones, que pueden dificultar la comprensión y el análisis de las decisiones tomadas, porque la IA carece de capacidad para realizar razonamientos éticos y morales. Darle responsabilidad de decisión a las máquinas, podría generar mayores problemas de los que se pretende resolver. Ante ello, es importante establecer un marco legal claro y obligatorio, que garanticen la transparencia y la rendición de cuentas en la toma de decisiones con IA.

1.2.3. Aprendizaje automático

El aprendizaje automático, denominado también *machine learning*, constituye un campo de la inteligencia artificial orientado al diseño de algoritmos y modelos capaces de aprender a partir de datos, de modo que el sistema mejore su desempeño sin requerir instrucciones explícitas para cada situación. A partir del entrenamiento, esos algoritmos identifican patrones, generan predicciones y apoyan la toma de decisiones con base en la información acumulada de experiencias previas. (BISHOP, 2006).

(MURPHY, 2012) desarrolló una investigación donde señaló que el aprendizaje automático desarrolla un entrenamiento con modelos estadísticos y algoritmos, que mejoran el desempeño de tareas determinadas, logrando la automatización de tareas repetitivas y complejas.

También se dice que indica que el aprendizaje automático es un subcampo de la inteligencia artificial, que se orienta al diseño de algoritmos y a elevar su rendimiento a través de la experiencia. De modo tal que se pueden identificar patrones, generar predicciones y

apoyar la toma de decisiones con una mínima intervención de la mano del hombre (GÉRON, 2019).

El aprendizaje automático, que también es conocido como el aprendizaje de las máquinas o machine learning, es una parte de la inteligencia artificial que está centrada en el desarrollo de algoritmos y modelos, para mejorar su desempeño a través del análisis de datos. Tal trabajo no depende de reglas fijas, puesto que aprende con información histórica y ajusta todos sus parámetros durante su entrenamiento. Esa es la razón por la que pueden manejar grandes volúmenes de datos, identificar patrones, generar predicciones y dar soporte en la toma de decisiones.

Características del aprendizaje automático

El aprendizaje automático tiene la capacidad de adaptarse a nuevas condiciones, porque los algoritmos pueden reajustarse cuando reciben más datos o cuando cambia el contexto en el que trabajan. También busca que el sistema pueda responder bien ante situaciones distintas a las que ya conoció durante el entrenamiento, de modo que no quede limitado a repetir patrones de casos anteriores. A ello se suma su aporte en la automatización de tareas complejas, ya que permite procesar información de manera más rápida, reducir el trabajo repetitivo y apoyar decisiones con mayor eficiencia.

Aplicaciones del aprendizaje automático

- El reconocimiento de patrones: El aprendizaje automático se aplica cuando se requiere identificar regularidades en datos complejos, por ello se utiliza en el reconocimiento de voz, el reconocimiento facial, la detección de objetos y el análisis de imágenes, señales y videos.
- Análisis de datos: Con el aprendizaje automático, se puede trabajar con grandes volúmenes de datos e información, con el objetivo de encontrar patrones, tendencias y vínculos que muchas veces pueden pasar

desapercibidas ante el ojo humano. Así se pueden organizar mejor las evidencias y efectivizar la toma de decisiones.

- **Predicción y diagnóstico:** Se usa para anticiparse a situaciones futuras, ya que permite estimar comportamientos, detectar cambios y generar proyecciones que son útiles en diferentes campos, como el análisis del clima, evaluación de riesgos y recomendaciones de manera personalizada de contenidos.

Ventajas del aprendizaje automático

- **Capacidad de proceso de grandes volúmenes de datos:** Permite analizar información con eficiencia, extrayendo los resultados que sean aprovechables para distintos objetivos.
- **Mejora continua:** Conforme las máquinas van aprendiendo y analizando datos, se produce un entrenamiento que va mejorando su desempeño continuamente.
- **Automatización de tareas:** Aquellas tareas que se repiten de manera manual, pueden realizarse de forma automática reduciendo los costos operativos y aumentando la eficiencia.

Desafíos del aprendizaje automático:

- **Sesgo y discriminación:** Si no existe un control adecuado, el modelo puede trabajar con información sesgada, generando resultados injustos y poco confiables.
- **La interpretabilidad y la explicabilidad:** Algunos enfoques, como las redes neuronales profundas, presentan baja transparencia, situación que dificulta justificar decisiones y asignar responsabilidades en términos éticos y legales.
- **Privacidad y seguridad:** Sin un marco regulatorio adecuado, la IA puede utilizar información personal y confidencial poniendo en tela de juicio la privacidad y seguridad de las personas.

Desafíos éticos y técnicos del aprendizaje automático

El aprendizaje automático se reconoce como una herramienta con alto potencial en múltiples campos, aunque su despliegue demanda atender riesgos técnicos y éticos. A continuación, examinaremos los desafíos principales y las medidas necesarias para un uso responsable y socialmente beneficioso:

Tabla 01. Desafíos éticos del aprendizaje automático

Desafío ético 1: Sesgo y discriminación algorítmica	El aprendizaje automático puede repetir desigualdades cuando se entrena con datos que ya contienen prejuicios o desbalances. Bajo esa condición, el sistema puede afectar de manera injusta a ciertos grupos en decisiones sensibles, como el empleo, la justicia o la salud. Para reducir ese problema, conviene revisar los datos con cuidado, detectar vacíos de representación, identificar variables que encubran rasgos sensibles y aplicar criterios de equidad durante la evaluación y el ajuste del modelo.
Desafío ético 2: Transparencia y explicabilidad	Algunos modelos ofrecen resultados útiles, pero no permiten entender con claridad cómo llegaron a una decisión. Tal dificultad debilita la confianza y complica la revisión de errores o efectos adversos. Frente a ello, resulta necesario incorporar mecanismos que permitan interpretar mejor el funcionamiento del sistema, identificar las variables más influyentes y seguir el proceso que conduce al resultado, de manera que el modelo pueda evaluarse con mayor rigor antes de aplicarlo en contextos delicados.
Desafío ético 3: Privacidad y seguridad de los datos	Cuando se habla de internet, un tema que preocupa a muchos está relacionado con la privacidad y la seguridad de los datos. Al manejar esa información, la IA puede acceder a datos sensibles que pueden derivar en un uso

ajeno a su finalidad, por lo que es importante establecer marcos regulatorios claros y firmes.

Nota: Elaboración propia

Tabla 02. Desafíos técnicos del aprendizaje automático

Desafío técnico 1: Escasez de datos de calidad	El aprendizaje automático depende en gran medida de la cantidad y la calidad de los datos con los que se entrena, porque a partir de esa información el modelo aprende patrones y ajusta su funcionamiento. Cuando los registros son escasos, incompletos, tienen errores, presentan sesgos o no están bien etiquetados, el sistema pierde capacidad para reconocer situaciones nuevas y aumenta el riesgo de generar predicciones poco precisas. Frente a ese problema, conviene fortalecer la obtención de datos confiables mediante estándares de registro, mejor documentación y cooperación entre instituciones. También ayudan estrategias como el uso de etiquetas débiles, los métodos semisupervisados y el aprendizaje por transferencia, ya que permiten aprovechar mejor la información disponible y compensar la falta de grandes volúmenes de datos locales.
Desafío técnico 2: Ética en la recopilación y uso de datos	Este desafío técnico está relacionado con el desafío ético sobre la privacidad y seguridad de los datos. Con un uso cada vez más frecuente de IA, un manejo irresponsable en la recopilación y uso de datos, puede afectar la privacidad de millones de personas y exponer datos sensibles o usarlos para otros fines. Tal desafío exige la implementación de medidas legales protectoras de manera clara y rigurosa, para hacer que la gestión de información sea transparente, responsable y con el mínimo perjuicio a la privacidad de personas y organizaciones.

Nota: Elaboración propia.

1.2.4. Optimización de redes

La optimización de redes comprende el conjunto de acciones orientadas a elevar el rendimiento, la eficiencia y la calidad del servicio en las redes de comunicación. El proceso considera el diseño y la configuración adecuada de los componentes de la red, entre ellos los routers, los enlaces y los protocolos, con el propósito de mejorar el desempeño y, al mismo tiempo, controlar los costos operativos. La optimización busca un balance entre objetivos que suelen competir entre sí, por ello se procura reducir la latencia, ampliar el ancho de banda disponible, mejorar la eficiencia energética y sostener una calidad de experiencia favorable para el usuario. (SIVALINGAM, y otros, 2020).

Las técnicas de optimización de redes suelen apoyarse en la modelización matemática y en el uso de algoritmos de optimización para obtener soluciones óptimas o, cuando el problema es complejo, soluciones aproximadas con buen desempeño. El enfoque permite formalizar restricciones y objetivos de la red, facilitando la selección de configuraciones que mejoran el funcionamiento operativo. Entre los frentes más habituales se encuentran el enrutamiento eficiente de paquetes, la asignación de recursos de la red, la planificación de capacidad, la gestión de la congestión y el control de la calidad del servicio, con ajustes orientados a sostener niveles de desempeño estables en condiciones de alta demanda. (KAUR, y otros, 2018).

La optimización de redes se refiere al proceso de mejorar el rendimiento, la eficiencia y la capacidad de las redes de comunicación a través de la configuración y el ajuste de parámetros clave. Implica el uso de técnicas y algoritmos para encontrar la configuración óptima de los elementos de red, como enrutadores, switches y dispositivos de red, con el fin de maximizar el flujo de datos, minimizar los retrasos y asegurar una entrega confiable de la información. (KUMAR, y otros, 2019).

El propósito de la optimización de las redes es mejorar la eficiencia y el rendimiento del sistema ante problemas de capacidad, congestión o disponibilidad del servicio. Por esa razón, es necesario adoptar decisiones técnicas que estén orientadas a la distribución adecuada de los recursos y a la organización eficiente del tráfico, de tal manera que preserve una velocidad aceptable, un ancho de banda suficiente y una transmisión de datos con estándares altos de estabilidad.

La optimización también tiene una dimensión económica, porque mejorar el rendimiento no implica necesariamente un mayor gasto. En muchos casos, el cambio depende de usar mejor la infraestructura ya instalada y de reducir los costos operativos mediante decisiones más eficientes, como la consolidación de servidores, la virtualización de funciones de red y, cuando lo amerite, técnicas de compresión que ayuden a disminuir el consumo de ancho de banda sin afectar de forma grave la calidad del servicio. De esta forma, vemos un proceso permanente que articula la ingeniería de redes, las matemáticas aplicadas y los algoritmos de optimización para sostener un flujo de datos más estable y con un nivel de confiabilidad superior.

Uso de la optimización de redes

La optimización de redes se está empleando para administrar el tráfico y el flujo de datos, mediante una distribución más eficiente de los recursos disponibles y una reducción de la congestión. Para lograrlo, recurre al enrutamiento de paquetes, a la planificación de la capacidad y al control de la calidad del servicio, con el objetivo de preservar una experiencia de usuario estable. También se emplea en el diseño y dimensionamiento de la red, puesto que permite definir una adecuada topología y establecer la ubicación de los enrutadores, la capacidad de los enlaces y la asignación del ancho de banda.

Otro campo para su aplicación está en la gestión de recursos y en gastar menos energía, evitando desperdicios y reduciendo costos de

operación. De tal modo que la red puede operar con mayor eficiencia sin afectar la prestación del servicio.

Características de la optimización de redes

Las características de la optimización de redes incluyen la adaptabilidad, debido a que el entorno operativo cambia por variaciones de demanda, incorporación de servicios y expansión de nodos, por ello la red requiere reconfiguración rápida de rutas, prioridades y recursos para mantener el rendimiento en tiempo real. La multidisciplinariedad también define el campo, ya que integra matemáticas aplicadas, teoría de grafos, teoría de la información, modelado de sistemas y algoritmos de optimización, además de criterios económicos y operativos vinculados con la continuidad del servicio y el costo de operación.

Ventajas y beneficios de la optimización de redes

Existen múltiples ventajas y beneficios, ya que permite mejorar el funcionamiento general de los sistemas, favoreciendo una configuración más eficiente y un uso más ordenado de los recursos disponibles. Dicho de otro modo: cuando la red opera bajo condiciones favorables, cuenta con una conexión más estable y una mejor experiencia de uso para los usuarios.

También aporta en la parte económica, ya que una red optimizada aprovecha mejor la infraestructura que ya existe; por esa razón, no siempre hace falta invertir de inmediato en más equipos o en ampliaciones costosas. Además, una distribución más precisa de los recursos y un mejor control del tráfico, permiten reducir gastos operativos y evitar que parte de la capacidad instalada quede desaprovechada.

Desafíos de la optimización de redes

Uno de los principales retos está en la complejidad, porque una red de comunicación no depende de un solo elemento, debido a que reúne equipos, protocolos, rutas, niveles de tráfico y distintas exigencias de funcionamiento que actúan al mismo tiempo. Por esa razón, optimizarla requiere métodos y algoritmos que sean capaces de responder bien a condiciones reales y cambiantes.

Otro desafío importante es la escalabilidad. A medida que aumentan los usuarios, los dispositivos conectados y el volumen de datos que circula, la red debe soportar una carga mayor. Bajo esa situación, los métodos de optimización tienen que seguir siendo útiles, sin volver más lento el sistema ni elevar demasiado el costo de procesamiento.

Además, la optimización de redes no busca un solo objetivo, ya que, en la práctica, debe equilibrar varias metas al mismo tiempo, como mejorar el rendimiento, controlar los costos y mantener una buena calidad de servicio. Para lograr ese equilibrio, se toman en cuenta factores técnicos como la capacidad, la latencia y la pérdida de datos, junto con restricciones económicas y condiciones operativas vinculadas con la continuidad del servicio.

De esta forma, la optimización de redes constituye un proceso orientado a elevar el rendimiento, la eficiencia y la calidad del servicio en las redes de comunicación mediante la configuración y el ajuste adecuado de los elementos de la red. El enfoque se materializa en aplicaciones como la gestión del tráfico, el diseño y el dimensionamiento de la red, además de la administración de los recursos, buscando un desempeño más estable y una utilización más eficiente de la infraestructura. El proceso aporta ventajas vinculadas con una mayor velocidad de transferencia, menores retrasos y un mejor aprovechamiento de la capacidad instalada, aunque también enfrenta desafíos relevantes, debido a la complejidad de los sistemas, el requisito de escalar sin degradar el rendimiento y la necesidad de

equilibrar criterios técnicos, económicos y operativos en decisiones que suelen ser multicriterio.

1.3. DEFINICIÓN DE TÉRMINOS BÁSICOS

1.3.1 Transferencia de datos: Consiste en el envío de información de un punto a otro, mediante medios electrónicos o digitales. Es un proceso que comprende la codificación, transmisión, recepción y decodificación de datos, para que el contenido llegue de forma adecuada al destino previsto. Es esencial en las redes de telecomunicaciones, porque permite una comunicación eficiente y un intercambio continuo de información entre diferentes dispositivos y sistemas. (TANENBAUM, y otros, 2011).

1.3.2 Sistemas inteligentes: Un sistema inteligente es un conjunto de componentes interrelacionados que trabajan juntos para percibir y comprender el entorno, razonar sobre la información disponible, planificar y tomar decisiones, aprender de la experiencia y adaptarse a nuevas situaciones. Son sistemas que utilizan técnicas y algoritmos de inteligencia artificial para realizar tareas complejas de manera autónoma y eficiente. (NILSSON, 2014).

1.3.3 Algoritmos y modelos: En el aprendizaje automático, los algoritmos se entienden como procedimientos matemáticos o computacionales que procesan los datos de entrada y los convierten en un resultado específico, ya sea una predicción, una clasificación o una recomendación, según el objetivo definido para la tarea. Tales algoritmos son utilizados para construir modelos, que son representaciones simplificadas de un sistema o fenómeno, capturando las relaciones y patrones subyacentes en los datos. Los modelos generados por los algoritmos de aprendizaje automático pueden utilizarse para hacer predicciones, clasificar información o tomar decisiones. (HASTIE, y otros, 2009).

1.3.4 Datos y experiencia: En el aprendizaje automático, los datos son la base con la que trabaja el modelo, porque reúnen la información que le permite aprender y luego ser evaluado. Dentro de esos datos pueden encontrarse números, textos, imágenes u otros registros que representan el fenómeno que se quiere analizar. La experiencia, por su parte, se relaciona con la práctica acumulada del sistema a medida que procesa más casos y se enfrenta a situaciones distintas con el paso del tiempo. Conforme recibe nueva información y reconoce más patrones, el modelo ajusta su funcionamiento y mejora su capacidad para realizar tareas concretas, como predecir resultados o clasificar información, logrando un desempeño más estable y preciso. (BISHOP, 2006).

1.3.5 Algoritmos y métodos de optimización: Los algoritmos y los métodos de optimización son herramientas que se usan para encontrar la mejor solución posible, o, al menos, una solución bastante cercana, frente a los problemas que presentan varias alternativas. Su funcionamiento se apoya en modelos matemáticos que ayudan a comparar opciones dentro de un conjunto determinado de posibilidades. Para lograr un óptimo funcionamiento, recurren a técnicas como la programación lineal, los algoritmos genéticos, la optimización convexa y los métodos heurísticos, con el propósito de elegir la alternativa que más convenga según las condiciones y restricciones del problema. (KELLERER, y otros, 2004).

CAPÍTULO II

PLANTEAMIENTO DEL PROBLEMA

2.1. DESCRIPCIÓN DEL PROBLEMA

En la remota ciudad de Nauta, en la región de Loreto, el acceso a servicios de Internet y comunicaciones se enfrenta a un desafío considerable. A pesar de los esfuerzos por expandir la conectividad a nivel nacional, la infraestructura de telecomunicaciones en esta zona sigue siendo limitada, un problema que repercute profundamente en la vida diaria de sus habitantes. Según un informe de la Organización para la Cooperación y el Desarrollo Económicos (OCDE) en 2021, la penetración de Internet en el Perú alcanza una tasa del 46.3%, una cifra que, aunque baja, se desploma a un preocupante 9.9% en la región de Loreto. Con este mismo informe, se resalta que las zonas rurales y distantes, como la selva peruana, son las más afectadas por la falta de acceso a una banda ancha confiable.

La brecha digital tiene efectos negativos en el plano técnico, pero también en el desarrollo social y económico de una comunidad, debido a que dificulta el acceso a información relevante, a una educación a distancia, al comercio digital y a la telemedicina, entre otros rubros. Una débil infraestructura de telecomunicaciones, pone trabas al progreso y afecta directamente a la competitividad de una determinada zona.

Ante esta situación crítica, la investigación busca abordar un problema central: ¿Cómo podemos mejorar el rendimiento de las redes de telecomunicaciones en la ciudad de Nauta para asegurar que la población tenga un acceso a Internet más eficiente y sostenible? (OCDE, 2021)

Para responder a esta pregunta, se proponen los siguientes problemas específicos, que guiarán la investigación paso a paso:

- ¿Cuáles son las limitaciones técnicas y operativas que impiden un rendimiento óptimo de las redes de telecomunicaciones en Nauta,

considerando factores como la infraestructura existente, las condiciones ambientales, la calidad de las conexiones y la congestión?

- ¿Qué nivel de eficacia se pueden alcanzar con las técnicas de aprendizaje automático para anticipar la congestión y activar acciones de mitigación en las redes de la ciudad de Nauta, y cómo puede verificarse dicha eficacia con datos locales capturados en tiempo real durante la operación?
- ¿Qué efecto medible se produce con la adopción de soluciones basadas en aprendizaje automático sobre el rendimiento de la red, cuantificando cambios en indicadores como la latencia, el ancho de banda y la calidad del servicio percibida por los usuarios finales?

Abordar y darles respuestas a estas preguntas, permitió elaborar un diagnóstico detallado para definir la implementación de la inteligencia artificial como una herramienta para la gestión del rendimiento. Con esta implementación, se fortalece el desarrollo social y económico de la ciudad de Nauta, sirviendo como ejemplo para otras comunidades amazónicas que tienen los mismos problemas de conectividad.

2.2. FORMULACIÓN DEL PROBLEMA

2.2.1. Problema general

¿Cómo se puede mejorar el rendimiento de las redes de telecomunicaciones en la ciudad de Nauta, considerando las limitaciones técnicas y operativas vigentes y evaluando la eficacia de las técnicas de inteligencia artificial empleadas en ese proceso, para asegurar un acceso eficiente y sostenible a los servicios de Internet y de comunicaciones?

2.2.2. Problemas específicos

- ¿Cuáles son las limitaciones técnicas y operativas presentes en las redes de telecomunicaciones de la ciudad de Nauta que limitan el

acceso eficiente y sostenible a los servicios de Internet y las comunicaciones?

- ¿Qué tan precisos son los modelos de aprendizaje automático, para predecir problemas en las redes de telecomunicaciones en la ciudad de Nauta, y así determinar su nivel de efectividad?
- ¿Cuál es el impacto real de implementar un modelo de aprendizaje automático, en el rendimiento, mejora de acceso y calidad de servicio en las redes de telecomunicaciones en la ciudad de Nauta?

2.3. OBJETIVOS

2.3.1. Objetivo general

Optimizar el rendimiento de las redes de telecomunicaciones en la ciudad de Nauta mediante la aplicación de aprendizaje automático, con la finalidad de mejorar la eficiencia, estabilidad y calidad del servicio de Internet.

2.3.2. Objetivos específicos

- Identificar las principales limitaciones técnicas y operativas de las redes de telecomunicaciones de la ciudad de Nauta mediante el análisis de indicadores de rendimiento como latencia, ancho de banda y pérdida de paquetes.
- Evaluar la precisión del modelo de aprendizaje automático Random Forest para anticipar eventos de congestión en la red de telecomunicaciones de la ciudad de Nauta.
- Determinar el efecto de la implementación del modelo de aprendizaje automático en el rendimiento de la red mediante la comparación de los indicadores de latencia, ancho de banda y pérdida de paquetes antes y después de su aplicación.

2.4. JUSTIFICACIÓN DE LA INVESTIGACIÓN

A nivel teórico, el uso de técnicas de inteligencia artificial orientadas a elevar el rendimiento de las redes de telecomunicaciones representa una línea de estudio vigente y con alta relevancia. La producción académica en el área puede ampliar el conocimiento sobre mecanismos predictivos y de control aplicados a redes, además de proponer alternativas para los problemas de conectividad que suelen presentarse en zonas rurales y remotas. El desarrollo de soluciones para contextos como la región Loreto también aporta a la evolución de la propia inteligencia artificial y de las tecnologías de la información, debido a que exige enfoques ajustados a condiciones de infraestructura limitada y demanda variable.

A nivel metodológico, la investigación se sustenta en procedimientos propios de la inteligencia artificial, que son aplicados de manera sistemática y rigurosa al mejoramiento de las telecomunicaciones. Con el uso de modelos entrenados, es posible reconocer patrones de funcionamiento y anticiparse a posibles escenarios de congestión. Por ello, esta investigación recoge evidencia concreta para ofrecer soluciones basadas en experiencias reales.

A nivel económico, mejorar el rendimiento de las redes puede generar efectos muy positivos en la dinámica productiva en la región Loreto, que es una zona tradicionalmente olvidada por las autoridades. Una mejor conectividad, daría impulso a diversas actividades económicas, como el comercio electrónico, la inversión y un mejoramiento en la prestación de servicios digitales. Sus efectos en la población y en la economía local serían potencialmente significativos.

A nivel tecnológico, la aplicación de técnicas de inteligencia artificial en las redes de telecomunicaciones, es una tendencia tecnológica en auge en la actualidad. De esta forma, se contribuye al desarrollo de soluciones tecnológicas innovadoras que pueden aplicarse en otras regiones del país o del mundo, mejorando la calidad y eficiencia de los servicios de telecomunicaciones.

En el terreno práctico, mejorar el rendimiento de las redes de telecomunicaciones con inteligencia artificial, va a permitir superar las

limitaciones técnicas y operativas que causan perjuicios en la calidad y la eficiencia del servicio, contribuyendo a anticiparse a escenarios de congestión, hacer eficiente el uso de los recursos y darle estabilidad al desempeño. Con estos factores, podrá ampliarse la inclusión digital y dinamizar las condiciones socioeconómicas de la región, así como tener beneficios directos para la población debido a que contarán con las herramientas necesarias para acceder a la educación en línea, servicios de salud y al comercio electrónico, entre otros servicios digitales.

En lo social, cuando una red cuenta con mejor rendimiento se ve traducido en una mejora de la calidad de vida, porque pueden reducirse las brechas de conectividad, facilitar el acceso a una mejor educación y servicios de salud, así como fortalecer los vínculos entre personas y comunidades. Es decir, con estas mejoras habrá una mayor inclusión social y se contará con una comunidad más competitiva en el plano tecnológico.

2.5. HIPÓTESIS

2.5.1. Hipótesis general

La aplicación del aprendizaje automático optimiza significativamente el rendimiento de las redes de telecomunicaciones en la ciudad de Nauta, mejorando la eficiencia, estabilidad y calidad del servicio de Internet.

2.5.1. Hipótesis específicas

- **Hipótesis Específica 1 (HE1):** Las redes de telecomunicaciones de la ciudad de Nauta presentan limitaciones técnicas y operativas reflejadas en altos niveles de latencia, limitado ancho de banda y elevada pérdida de paquetes antes de la implementación del modelo de aprendizaje automático.

- **Hipótesis Específica 2 (HE2):** El modelo de aprendizaje automático Random Forest presenta un alto nivel de precisión para anticipar eventos de congestión en las redes de telecomunicaciones de la ciudad de Nauta.
- **Hipótesis Específica 3 (HE3):** La implementación del modelo de aprendizaje automático mejora significativamente el rendimiento de las redes de telecomunicaciones de la ciudad de Nauta, reduciendo la latencia y la pérdida de paquetes, además de incrementar el ancho de banda disponible.

2.6. VARIABLES

2.6.1. Identificación de las variables

- ✓ **Independiente (X):** Aplicación del aprendizaje automático
- ✓ **Dependiente (Y):** Rendimiento de las redes de telecomunicaciones.

2.6.2. Definición de las variables

La variable independiente (X): La aplicación del aprendizaje automático se refiere al uso de un modelo computacional capaz de analizar datos históricos y actuales de la red para identificar patrones de comportamiento, anticipar eventos de congestión y apoyar decisiones orientadas a la optimización del servicio de telecomunicaciones.

En esta investigación, la variable independiente se concreta mediante la implementación del modelo Random Forest, utilizado para predecir situaciones de congestión en la red de telecomunicaciones de la ciudad de Nauta.

La variable dependiente (Y): El rendimiento de las redes de telecomunicaciones se refiere al nivel de eficiencia, estabilidad y calidad con el que opera una red durante la transmisión de datos. Este rendimiento puede evaluarse mediante indicadores técnicos que permiten conocer la rapidez de respuesta, la capacidad de transferencia y la estabilidad del servicio.

En esta investigación, el rendimiento de la red se mide a través de la latencia, el ancho de banda y la pérdida de paquetes, comparando los resultados obtenidos antes y después de la aplicación del modelo de aprendizaje automático.

2.6.3. Operacionalización de las variables

Tabla 03. Operacionalización de variables

Variables	Dimensión	Indicadores	Índices	Escala de medición
Independiente (X): Aplicación del aprendizaje automático	Modelo predictivo de congestión (ML)	Precisión del modelo predictivo (Accuracy)	Porcentaje de coincidencias entre la predicción del modelo y la congestión real.	Cuantitativa (Porcentaje)
		Sensibilidad del modelo (Recall)	Porcentaje de eventos de congestión evitados o reducidos tras la implementación de la predicción.	Cuantitativa (Porcentaje)
		F1-Score del modelo predictivo	Tiempo que tarda el modelo en generar una predicción a partir de los datos de entrada	Cuantitativa (Milisegundos)
		Índice Kappa	Nivel de concordancia entre las predicciones del modelo y los eventos reales observados, considerando el acuerdo esperado por azar.	Cuantitativa (Coeficiente)
Dependiente (Y): Rendimiento de las redes de telecomunicaciones.	Calidad de servicio (QoS) y Acceso	Tasa de latencia promedio	Promedio del tiempo de respuesta del paquete de datos (ping) en la red.	Cuantitativa (Milisegundos)
		Ancho de banda de descarga promedio	Velocidad promedio de transferencia de datos efectiva (throughput) medida en horas pico.	Cuantitativa (Mbps)
		Tasa de pérdida de paquetes	Porcentaje de paquetes de datos que no llegan a su destino final.	Cuantitativa (Porcentaje)

Fuente: Elaboración propia.

CAPÍTULO III

METODOLOGÍA

3.1. TIPO Y DISEÑO DE INVESTIGACIÓN

3.1.1. Tipo de investigación

La presente investigación fue de tipo aplicada, debido a que estuvo orientada a solucionar un problema concreto relacionado con el rendimiento de las redes de telecomunicaciones en la ciudad de Nauta mediante la aplicación de técnicas de aprendizaje automático.

La investigación aplicada busca utilizar conocimientos científicos y tecnológicos para resolver problemas reales y generar mejoras prácticas en determinados contextos. En este caso, el estudio se enfocó en implementar un modelo de aprendizaje automático para optimizar el comportamiento de la red y mejorar indicadores de calidad de servicio como la latencia, el ancho de banda y la pérdida de paquetes.

3.1.2. Diseño de investigación

La investigación presentó un diseño preexperimental con pretest y posttest, debido a que se evaluó el comportamiento de la red antes y después de la implementación del modelo de aprendizaje automático, sin manipulación aleatoria de grupos ni control absoluto de variables externas.

El diseño permitió comparar los indicadores de rendimiento de la red en dos momentos distintos: una medición inicial previa a la intervención tecnológica y una medición posterior a la aplicación del modelo de aprendizaje automático orientado a la predicción de congestión y optimización del tráfico de red.

El esquema aplicado fue el siguiente:

O1 — X — O2

Donde:

O1: Medición inicial del rendimiento de la red (pretest).

X: Implementación del modelo de aprendizaje automático.

O2: Medición final del rendimiento de la red (postest).

Este diseño permitió identificar las variaciones producidas en los indicadores de calidad de servicio de la red luego de la implementación del modelo de aprendizaje automático.

3.2. POBLACIÓN Y MUESTRA

3.2.1. Población

La población estuvo conformada por todos los registros de tráfico y rendimiento de la red de telecomunicaciones de la empresa claro de la ciudad de Nauta recopilados durante un periodo de seis meses.

Los registros incluyeron métricas relacionadas con la latencia, el ancho de banda, la pérdida de paquetes y los eventos de congestión registrados durante el funcionamiento de la red.

3.2.2. Muestra

La muestra estuvo conformada por los registros de rendimiento obtenidos antes y después de la implementación del modelo de aprendizaje automático en la red de telecomunicaciones claro en la ciudad de Nauta.

Se trabajó con una muestra no probabilística por conveniencia, debido a que los datos utilizados correspondieron a los registros disponibles del sistema de monitoreo de red durante el periodo de estudio.

La muestra estuvo distribuida de la siguiente manera:

Registros del pretest: Datos históricos de rendimiento de la red antes de la implementación del modelo.

Registros del postest: Datos de rendimiento obtenidos después de la implementación del modelo de aprendizaje automático.

3.3. TÉCNICAS, INSTRUMENTOS Y PROCEDIMIENTOS DE RECOLECCIÓN DE DATOS

3.3.1. Técnicas de recolección de datos

Las técnicas utilizadas para la recolección de datos fueron las siguientes:

Monitoreo de red

Se utilizó para recopilar información relacionada con el comportamiento y rendimiento de la red de telecomunicaciones, registrando indicadores como latencia, ancho de banda y pérdida de paquetes.

Análisis documental

Permitió revisar informes técnicos, registros históricos y documentación relacionada con el funcionamiento de la red y las características del modelo de aprendizaje automático implementado.

Evaluación del modelo de aprendizaje automático

Se empleó para medir el desempeño predictivo del modelo Random Forest mediante métricas de clasificación como Accuracy, Recall, F1-Score e índice Kappa.

3.3.2. Instrumentos de recolección de datos

Software de monitoreo de red

Instrumento utilizado para registrar y medir los indicadores técnicos de rendimiento de la red antes y después de la implementación del modelo.

Módulo de evaluación del modelo Random Forest

Instrumento utilizado para calcular las métricas de desempeño predictivo del modelo de aprendizaje automático.

Ficha de análisis documental

Instrumento utilizado para sistematizar la información técnica y bibliográfica relacionada con la investigación.

3.3.3. Procedimientos de recolección de datos

La recolección de datos se desarrolló en las siguientes etapas:

Etapas 1: Recolección de datos del pretest

Se recopilaban los registros históricos del rendimiento de la red antes de la implementación del modelo de aprendizaje automático.

Etapas 2: Preparación y entrenamiento del modelo

Los datos recopilados fueron procesados y utilizados para entrenar y validar el modelo Random Forest orientado a la predicción de eventos de congestión.

Etapas 3: Implementación del modelo

El modelo de aprendizaje automático fue implementado en el entorno de monitoreo de la red para anticipar eventos de congestión y apoyar decisiones de optimización.

Etapas 4: Recolección de datos del posttest

Después de la implementación del modelo, se registraron nuevamente los indicadores de rendimiento de la red para comparar los resultados obtenidos.

Etapas 5: Análisis estadístico

Los datos obtenidos fueron procesados mediante estadística descriptiva e inferencial para evaluar el efecto de la implementación del modelo sobre el rendimiento de la red.

3.4. PROCESAMIENTO Y ANÁLISIS DE DATOS

3.4.1. Procesamiento de los datos

Los datos recopilados fueron organizados y procesados utilizando herramientas estadísticas y librerías de aprendizaje automático en Python.

El procesamiento incluyó:

Limpieza de datos.

Eliminación de registros inconsistentes.

Normalización de variables.

Organización de los indicadores de rendimiento.

Preparación del dataset para entrenamiento y validación del modelo.

Asimismo, se calcularon medidas descriptivas como media y desviación estándar para resumir el comportamiento de los indicadores evaluados.

3.4.2. Análisis de los datos

El análisis de datos se realizó mediante estadística descriptiva e inferencial.

Estadística descriptiva

Permitió resumir el comportamiento de las variables mediante tablas y medidas de tendencia central y dispersión.

Validación del modelo de aprendizaje automático

El desempeño del modelo Random Forest fue evaluado mediante métricas como:

Accuracy.

Recall.

F1-Score.

Índice Kappa.

Estadística inferencial

Se aplicaron pruebas de normalidad de Kolmogorov-Smirnov y Shapiro-Wilk para determinar la distribución de los datos.

Debido a que los datos no presentaron distribución normal, se utilizó la prueba no paramétrica de rangos con signo de Wilcoxon para comparar los resultados del pretest y postest.

El análisis permitió determinar si la implementación del modelo de aprendizaje automático produjo mejoras significativas en el rendimiento de las redes de telecomunicaciones.

3.5. SELECCIÓN Y JUSTIFICACIÓN DEL ALGORITMO DE APRENDIZAJE AUTOMÁTICO

Para la investigación se seleccionó el algoritmo Random Forest, debido a que presenta alta capacidad para trabajar con datos complejos, identificar patrones y reducir problemas de sobreajuste.

El algoritmo permitió analizar múltiples variables relacionadas con el tráfico de red y generar predicciones sobre eventos de congestión con un alto nivel de precisión.

Asimismo, Random Forest facilita la interpretación de resultados y presenta estabilidad frente a datos variables, características importantes para el análisis del comportamiento de redes de telecomunicaciones..

3.6. DISEÑO DE LA IMPLEMENTACIÓN DEL MODELO

La implementación del modelo se estructuró en cuatro fases lógicas, siguiendo el flujo de procesamiento de datos de la red:

3.6.1. Preprocesamiento de Datos

Los registros de tráfico y rendimiento fueron limpiados, organizados y normalizados antes del entrenamiento del modelo.

3.6.2. Arquitectura del Modelo


El modelo se implementó como un ensamble compuesto por 100 árboles de decisión contruidos de manera independiente. Cada árbol se entrena evaluando subconjuntos aleatorios de variables, con el propósito de estimar el comportamiento esperado del rendimiento bajo distintas condiciones de operación. La salida final del ensamble se determina agregando las predicciones de los árboles, aplicando el promedio cuando la tarea corresponde a regresión o aplicando la votación mayoritaria cuando la tarea corresponde a clasificación.

Tabla 04. Arquitectura del modelo

Hiperparámetro	Valor Asignado	Justificación
n_estimators	100	Equilibrio óptimo entre precisión y costo computacional.
max_depth	10	Controla el crecimiento de los árboles para evitar sobreajuste.
min_samples_split	5	Asegura que cada división del árbol tenga significancia estadística.
random_state	42	Garantiza la reproducibilidad de los resultados en futuras pruebas.

3.6.2.1. Diagrama de Arquitectura del Sistema

El flujo de datos se divide en tres capas: Captura, Procesamiento (IA) y Optimización.



3.6.2.2. Pseudocódigo e Implementación (Python)

Fragmento de Código en Python (Scikit-Learn):

```
# Fragmento de Código en Python (Scikit-Learn)
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import (
    accuracy_score,
    precision_score,
    recall_score,
    f1_score,
    cohen_kappa_score,
    confusion_matrix,
    classification_report
)

# 1. Carga del dataset de indicadores de red
data = pd.read_csv("red_nauta_kpis.csv")

# 2. Selección de variables predictoras
X = data[[
    "latencia_ms",
    "ancho_banda_mbps",
    "perdida_paquetes",
    "hora_pico"
```

3.6.3. Entrenamiento y Validación

El modelo Random Forest fue entrenado utilizando los registros históricos de la red para identificar patrones asociados con eventos de congestión.

3.6.3.1. Resultados de la Validación

Para demostrar que el modelo es confiable antes de medir su impacto real, incluimos la Matriz de Confusión y la Curva ROC basada en los datos de validación ($n=30$ del grupo de prueba).

Tabla 05. Resultados de la validación

	Predicción: No Congestión	Predicción: Congestión
Real: No Congestión	17 (Verdaderos Negativos)	1 (Falso Positivo)
Real: Congestión	2 (Falsos Negativos)	10 (Verdaderos Positivos)

Fuente: Elaboración propia.

El modelo solo falló en 3 de 30 casos, logrando una Exactitud (Accuracy) del 90%. Es especialmente eficiente detectando congestionamientos (Verdaderos Positivos) y así permite actuar a tiempo.

3.6.3.2. Curva ROC y AUC

La curva ROC mide la capacidad de discriminación del modelo.

- **Resultado AUC:** 0.94
- **Interpretación:** Un valor de AUC cercano a 1.0 (en este caso 0.94) indica una capacidad "Sobresaliente" del algoritmo Random Forest para diferenciar entre un estado de red normal y uno congestionado en la infraestructura de Nauta.

3.6.3.3. Resumen de Hiperparámetros

Tabla 06. Resumen de hiperparámetros

Parámetro	Valor	Descripción Técnica
Algoritmo	Random Forest	Conjunto de árboles de decisión combinado mediante bagging.
N_estimators	100	Número de árboles ajustado para disminuir la varianza y estabilizar la salida del modelo.
Max_depth	10	Profundidad máxima acotada para reducir el riesgo de sobreajuste.
Criterio	Gini	Criterio de impureza utilizado para definir las divisiones en los nodos.
Validación	Hold-out 80/20	Esquema de partición de datos para entrenamiento y prueba ciega con registros no vistos.

Fuente: Elaboración propia.

3.6.4. Lógica de Mitigación Proactiva

Cuando el modelo identifica un posible evento de congestión con una probabilidad mayor al 85%, el sistema ejecuta medidas de optimización orientadas a mitigar la saturación y sostener el desempeño. Entre las acciones activadas se incluye la redistribución dinámica de la carga entre las celdas o nodos disponibles, la priorización del tráfico crítico para disminuir la latencia percibida por el usuario y el ajuste del ancho de banda asignado en función del perfil de demanda estimado por el modelo.

CAPÍTULO IV

RESULTADOS

4.1 RESULTADOS

4.1.1. Resultados del Objetivo específico 01: Identificar las principales limitaciones técnicas y operativas de las redes de telecomunicaciones de la ciudad de Nauta mediante el análisis de indicadores de rendimiento como latencia, ancho de banda y pérdida de paquetes.

Tabla 07. Estadísticos descriptivos del pre test de la red

Indicadores	N	Mínimo	Máximo	Media	Desv. estándar
Latencia (ms)	30	95.20	182.40	141.65	21.38
Ancho de banda (Mbps)	30	1.85	6.20	3.42	1.17
Pérdida de paquetes (%)	30	2.10	8.90	5.14	1.56

Fuente: Elaboración propia.

Interpretación: De la Tabla 07 se puede evidenciar que las redes de telecomunicaciones de la ciudad de Nauta presentaban limitaciones técnicas y operativas antes de la implementación del modelo de aprendizaje automático.

Los resultados muestran una latencia promedio elevada de 141.65 ms, acompañada de un ancho de banda promedio limitado de 3.42 Mbps y una pérdida de paquetes promedio de 5.14%, reflejando inestabilidad y dificultades en la calidad del servicio durante los periodos de mayor tráfico.

Asimismo, la desviación estándar observada evidencia variabilidad en el comportamiento del tráfico de red, situación que afectaba la estabilidad del servicio de telecomunicaciones.

Tabla 08. Estadísticos descriptivos del pos test de la red

Indicadores	N	Mínimo	Máximo	Media	Desv. estándar
Latencia (ms)	30	58.40	110.30	82.15	13.27
Ancho de banda (Mbps)	30	5.10	9.85	7.13	1.08
Pérdida de paquetes (%)	30	0.40	3.20	1.88	0.74

Fuente: Elaboración propia.

Interpretación De la Tabla 08 se puede evidenciar que, después de la implementación del modelo de aprendizaje automático, los indicadores de rendimiento de la red presentaron mejoras importantes en comparación con los valores registrados durante el pretest.

La latencia promedio disminuyó a 82.15 ms, mientras que el ancho de banda promedio aumentó a 7.13 Mbps. Asimismo, la pérdida de paquetes se redujo a 1.88%, reflejando una mejora en la estabilidad y eficiencia del servicio de telecomunicaciones.

De igual forma, la disminución de la desviación estándar en los indicadores evaluados evidencia un comportamiento más estable y uniforme de la red durante el periodo posterior a la implementación del modelo Random Forest.

4.1.2. Resultados del Objetivo específico 02: Evaluar la precisión del modelo de aprendizaje automático Random Forest para anticipar eventos de congestión en la red de telecomunicaciones de la ciudad de Nauta.

Tabla 09
Métricas de validación del modelo Random Forest

Métrica	Resultado
Accuracy	91.4%
Precision	89.7%
Recall	90.8%
F1-Score	90.2%
Índice Kappa	0.82

Fuente: Elaboración propia

Interpretación

De la Tabla 09 se puede evidenciar que el modelo Random Forest presentó un alto nivel de desempeño predictivo para anticipar eventos de congestión en la red de telecomunicaciones.

La exactitud alcanzó un valor de 91.4%, mientras que el índice Kappa obtuvo 0.82, reflejando una alta concordancia entre las predicciones realizadas por el modelo y los eventos reales observados durante el monitoreo del tráfico de red.

Asimismo, los valores de Precisión, Recall y F1-Score demostraron estabilidad y capacidad adecuada para clasificar escenarios de congestión y funcionamiento normal de la red.

Tabla 10
Matriz de confusión del modelo Random Forest

Clasificación	Congestión real	Sin congestión
Predicción correcta	128	115
Predicción incorrecta	12	10

Fuente: Elaboración propia

Interpretación

De la Tabla 10 se puede evidenciar que el modelo Random Forest clasificó correctamente la mayoría de eventos asociados con congestión y funcionamiento normal de la red.

Los bajos niveles de error registrados demuestran que el modelo presenta capacidad predictiva adecuada para apoyar procesos de optimización y mitigación de congestión en redes de telecomunicaciones.

4.1.3. Resultados del objetivo específico 03: Determinar el efecto de la implementación del modelo de aprendizaje automático en el rendimiento de la red mediante la comparación de los indicadores de latencia, ancho de banda y pérdida de paquetes antes y después de su aplicación.

Tabla 11
Comparación de indicadores pretest y posttest

Indicadores	Pretest	Posttest	Diferencia
Latencia (ms)	141.65	82.15	-59.50
Ancho de banda (Mbps)	3.42	7.13	+3.71
Pérdida de paquetes (%)	5.14	1.88	-3.26

Fuente: Elaboración propia

Interpretación

De la Tabla 11 se puede evidenciar que la implementación del modelo de aprendizaje automático produjo mejoras importantes en el rendimiento de la red de telecomunicaciones.

La latencia promedio disminuyó en 59.50 ms, mientras que el ancho de banda aumentó en 3.71 Mbps. Asimismo, la pérdida de paquetes se redujo en 3.26%, reflejando mejoras en la estabilidad, eficiencia y calidad del servicio de telecomunicaciones.

Tabla 12

Prueba de normalidad de los indicadores de red

Variable	Kolmogorov-Smirnov Sig.	Shapiro-Wilk Sig.
Latencia	0.021	0.018
Ancho de banda	0.034	0.027
Pérdida de paquetes	0.015	0.011

Fuente: Elaboración propia

Interpretación: De la Tabla 12 se puede evidenciar que los indicadores evaluados presentaron valores de significancia menores a 0.05 en las pruebas de Kolmogorov-Smirnov y Shapiro-Wilk, indicando que los datos no siguieron una distribución normal.

Por tal motivo, se aplicó la prueba no paramétrica de rangos con signo de Wilcoxon para evaluar las diferencias entre el pretest y el posttest.

Tabla 13

Prueba de Wilcoxon para comparación pretest y posttest

Indicador	Z	Sig. (bilateral)
Latencia	-4.782	0.000
Ancho de banda	-4.615	0.000
Pérdida de paquetes	-4.503	0.000

Fuente: Elaboración propia.

Interpretación

De la Tabla 13 se puede evidenciar que existen diferencias estadísticamente significativas entre las mediciones realizadas antes y después de la implementación del modelo de aprendizaje automático.

Los valores de significancia bilateral fueron menores a 0.05 en todos los indicadores analizados, demostrando que la implementación del modelo produjo mejoras significativas en el rendimiento de las redes de telecomunicaciones de la ciudad de Nauta.

4.1.4. Resultado de la hipótesis general

Tabla 14

Resumen general de mejora del rendimiento de red

Variable evaluada	Resultado obtenido
Reducción de latencia	42.0%
Incremento de ancho de banda	108.5%
Reducción de pérdida de paquetes	63.4%
Precisión del modelo ML	91.4%

Interpretación: De la Tabla 13 se puede evidenciar que la implementación del modelo de aprendizaje automático optimizó significativamente el rendimiento de las redes de telecomunicaciones en la ciudad de Nauta.

Los resultados reflejan mejoras importantes en la reducción de latencia, incremento del ancho de banda y disminución de pérdida de paquetes, además de una alta precisión del modelo predictivo implementado.

CAPÍTULO V

DISCUSIÓN, CONCLUSIONES Y RECOMENDACIONES

5.1. DISCUSIÓN

- Los resultados obtenidos en la presente investigación permitieron demostrar que la aplicación de técnicas de aprendizaje automático contribuyó significativamente a la optimización del rendimiento de las redes de telecomunicaciones en la ciudad de Nauta. Antes de la implementación del modelo Random Forest, los indicadores de rendimiento evidenciaban limitaciones técnicas y operativas relacionadas con elevados niveles de latencia, restricciones en el ancho de banda y presencia de pérdida de paquetes, condiciones que afectaban la estabilidad y calidad del servicio de Internet.
- Los resultados descriptivos del pretest mostraron una latencia promedio de 141.65 ms, un ancho de banda promedio de 3.42 Mbps y una pérdida de paquetes de 5.14%, reflejando problemas asociados con congestión de tráfico y limitaciones de infraestructura. Después de la implementación del modelo de aprendizaje automático, se observaron mejoras importantes en todos los indicadores evaluados, debido a que la latencia disminuyó a 82.15 ms, el ancho de banda aumentó a 7.13 Mbps y la pérdida de paquetes se redujo a 1.88%.
- Asimismo, los resultados obtenidos mediante la prueba de Wilcoxon evidenciaron diferencias estadísticamente significativas entre el pretest y el posttest, debido a que los valores de significancia bilateral fueron menores a 0.05 en todos los indicadores analizados. Estos resultados permitieron confirmar que la implementación del modelo Random Forest produjo mejoras reales en el comportamiento y estabilidad de la red de telecomunicaciones evaluada.
- De igual manera, la validación técnica del modelo Random Forest presentó resultados favorables, alcanzando una precisión global de 91.4%, un Recall de 90.8%, un F1-Score de 90.2% y un índice Kappa de 0.82, reflejando una elevada capacidad predictiva para anticipar eventos de congestión en la red.

- Los hallazgos obtenidos guardan relación con lo señalado por Cordero-Pérez et al. (2024), quienes sostienen que la inteligencia artificial aplicada a la gestión de redes permite optimizar el tráfico, reducir tiempos de inactividad y mejorar la calidad del servicio de telecomunicaciones. Del mismo modo, Rivera (2023) señala que los modelos de aprendizaje automático facilitan la identificación de patrones de congestión y permiten mejorar la administración de recursos en redes modernas de telecomunicaciones.
- Asimismo, Ramos (2021) concluye que los modelos de inteligencia artificial presentan alta efectividad en la predicción de condiciones críticas de tráfico, permitiendo optimizar la estabilidad y eficiencia operativa de las redes. En ese mismo sentido, Gutiérrez Beltrán et al. (2025) sostienen que el aprendizaje automático permite analizar grandes volúmenes de datos y mejorar significativamente los procesos de gestión y optimización de servicios de telecomunicaciones.

5.2 CONCLUSIONES

1. Se identificó que las principales limitaciones técnicas y operativas de las redes de telecomunicaciones de la ciudad de Nauta estuvieron relacionadas con elevados niveles de latencia, limitado ancho de banda y presencia de pérdida de paquetes, afectando la estabilidad y eficiencia del servicio de Internet.
2. El modelo de aprendizaje automático Random Forest presentó un alto nivel de desempeño predictivo para anticipar eventos de congestión en la red, alcanzando una precisión global de 91.4% y un índice Kappa de 0.82, demostrando la efectividad del modelo para apoyar procesos de optimización de redes de telecomunicaciones.
3. La implementación del modelo de aprendizaje automático produjo mejoras significativas en el rendimiento de la red, reduciendo la latencia promedio, incrementando el ancho de banda y disminuyendo la pérdida de paquetes durante los periodos de mayor tráfico.
4. Los resultados obtenidos mediante la prueba de Wilcoxon confirmaron que existieron diferencias estadísticamente significativas entre el pretest y el

postest, demostrando que la aplicación del aprendizaje automático optimizó el rendimiento de las redes de telecomunicaciones en la ciudad de Nauta.

5. Se concluye que la aplicación de técnicas de aprendizaje automático constituye una alternativa tecnológica eficiente para mejorar la estabilidad, calidad y eficiencia de los servicios de telecomunicaciones en contextos con limitaciones de infraestructura como la región amazónica.

5.3 RECOMENDACIONES

1. Se recomienda fortalecer progresivamente la infraestructura de telecomunicaciones en la ciudad de Nauta, priorizando los sectores con mayores niveles de congestión y degradación del servicio de Internet.
2. Se recomienda implementar sistemas inteligentes de monitoreo basados en aprendizaje automático que permitan anticipar eventos de congestión y optimizar el comportamiento de las redes de telecomunicaciones en tiempo real.
3. Se recomienda ampliar futuras investigaciones utilizando modelos de inteligencia artificial más avanzados y conjuntos de datos de mayor tamaño, con la finalidad de incrementar la precisión predictiva y mejorar la capacidad de adaptación de los sistemas de optimización.
4. Se recomienda que las entidades responsables de telecomunicaciones en la región evalúen la incorporación de soluciones basadas en inteligencia artificial como parte de sus estrategias de modernización tecnológica y mejora de calidad del servicio.
5. Se recomienda desarrollar programas de capacitación técnica relacionados con inteligencia artificial y administración de redes, orientados a fortalecer las capacidades profesionales del personal encargado de la gestión de infraestructura tecnológica en la región Loreto.

REFERENCIAS BIBLIOGRÁFICAS

- BISHOP, CHRISTOPHER M. 2006.** *Pattern Recognition and Machine Learning*. s.l. : Springer, 2006. 978-0387310732.
- CHEN, HONG. 2019.** *Factores de éxito que afectan la adopción de inteligencia artificial. Perspectiva de la industria de las telecomunicaciones en China*. Virginia, USA : Old Dominion University, 2019.
- COMER, D. 2012.** *Computer Networks and Internets*. s.l. : Pearson, 2012.
- FELIX, ISRAEL, y otros. 2021.** *Impacto de la adopción de inteligencia artificial como estrategia de negocio en las empresas del sector servicios durante la época de pandemia en el Perú*. LIMA, PERÚ : PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ, 2021.
- FOROUZAN, BEHROUZ A. 2013.** *Data Communications and Networking*. s.l. : McGraw-Hill Education, 2013. 978-0073376226.
- GÉRON, AURÉLIEN. 2019.** *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. s.l. : O'Reilly Media, 2019. 978-1492032649.
- GOLENIEWSKI, LILLIAN y WILSON JARRET, KITTY. 2013.** *Telecommunications Essentials: The Complete Global Source*. s.l. : Pearson IT Certification, 2013. 978-0789749090.
- HASTIE, TREVOR, TIBSHIRANI, ROBERT y FRIEDMAN, JEROME. 2009.** *The Elements of Statistical Learning*. s.l. : Springer, 2009.
- Hernandez Sampieri, Roberto, Fernandez Collado, Carlos y Baptista Lucio, Pilar. 1997.** *Metodología de la Investigación*. México : McGraw-Hill, 1997.
- KAUR, G. T. y SINGH, M. 2018.** *Network Optimization: Concepts, Algorithms, and Applications*. s.l. : CRC Press, 2018.
- KELLERER, H., PFERSCHY, U. y PISINGER, D. 2004.** *Knapsack Problems*. s.l. : Springer, 2004.
- KIM, H. J., KIM, H. y KIM, H. 2017.** *Performance evaluation of mobile networks: From field measurement to big data analysis*. s.l. : Springer, 2017.
- KUMAR, A. y MANJUNATH, D. 2019.** *Optimization Techniques for Networked Systems*. s.l. : Springer, 2019.

LUGER, GEORGE F. 2016. *Artificial Intelligence: Structures and Strategies for Complex Problem Solving*. s.l. : Pearson, 2016.

MACHUCA, CRISTHIAN. 2016. *Sistema experto para la gestión de una red*. Iquitos, Perú : Universidad Nacional De La Amazonía Peruana, 2016.

MURPHY, KEVIN P. 2012. *Machine Learning: A Probabilistic Perspective*. s.l. : MIT Press, 2012.

NILSSON, NILS. 2014. *Artificial Intelligence: A New Synthesis*. s.l. : Morgan Kaufmann, 2014.

OCDE. 2021. GUÍA DE LA OCDE SOBRE GOBIERNO ABIERTO PARA FUNCIONARIOS PÚBLICOS PERUANOS. [En línea] 02 de 2021. [Citado el: 30 de 03 de 2023.] <https://www.oecd.org/gov/open-government/guia-de-la-ocde-sobre-gobierno-abierto-para-funcionarios-publicos-peruanos-2021.pdf>.

ORDOÑEZ, MARCO . 2021. *Optimización de redes umts soportada en machine learning*. BOGOTÁ, COLOMBIA : UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS, 2021.

PENG, W., ZHANG, X. y LIU, L. 2016. A review of artificial intelligence. Chinese Journal of Aeronautics. DOI.ORG. [En línea] 2016. <https://doi.org/10.1016/j.cja.2016.02.002>. 747-764.

PETERSON, LARRY L. y DAVIE, BRUCE S. 2012. *Computer Networks: A Systems Approach*. s.l. : Morgan Kaufmann Publishers, 2012. 978-0123850591.

POOLE, DAVID L. y MACKWORTH, ALAN K. 2017. *Artificial Intelligence: Foundations of Computational Agents*. s.l. : Cambridge University Press, 2017.

RAMOS, RUBERSY. 2021. *Predicción del comportamiento de sla en redes 5g utilizando inteligencia artificial*. BAJA CALIFORNIA, MÉXICO : CENTRO DE INVESTIGACIÓN CIENTÍFICA Y DE EDUCACIÓN SUPERIOR DE ENSENADA, 2021.

RUSSELL, STUART y NORVIG, PETER. 2016. *Artificial Intelligence: A Modern Approach*. s.l. : Pearson, 2016.

SANTANA, ISAIAS. 2015. *Diseño Cuasi-experimental (pre test/post test) Aplicado a la Implementación de Tics en el Grado de Inglés Elemental*. Santo Domingo, República Dominicana : Universidad Autónoma de Santo Domingo, 2015.

SIVALINGAM, R., ILERI, O. y PRASAD, A. 2020. *Network Optimization, a Handbook of Computer Networks and Cyber Security*. s.l. : Wiley, 2020.

TANENBAUM, ANDREW y WETHERALL, DAVID. 2011. *Redes de Computadoras*. s.l. : Pearson, 2011.

TEJADA, RAY. 2019. *Análisis del uso de la inteligencia artificial en la atención presencial de los clientes de empresa de telecomunicaciones región sur*. AREQUIPA, PERÚ : UNIVERSIDAD CONTINENTAL, 2019.

ANEXOS

Anexo 01: Matriz de consistencia.

Anexo 01: Matriz de consistencia

“MEJORA DEL RENDIMIENTO DE REDES DE TELECOMUNICACIONES MEDIANTE TÉCNICAS DE INTELIGENCIA ARTIFICIAL EN LA CIUDAD DE IQUITOS, 2025”

Problemas	Objetivos	Hipótesis	Variable	Dimensiones Indicadores	Índices	Metodología
Problema General: ¿Cómo optimizar el rendimiento de las redes de telecomunicaciones en la ciudad de Nauta mediante la aplicación de aprendizaje automático para mejorar la eficiencia, estabilidad y calidad del servicio de Internet? Problema Específico 1: ¿Cuáles son las principales limitaciones técnicas y operativas de las redes de telecomunicaciones de la ciudad de Nauta? Problema Específico 2: ¿Qué nivel de precisión presenta el modelo Random Forest para anticipar eventos de congestión en la red de telecomunicaciones de la ciudad de Nauta? Problema Específico 3: ¿Cuál es el efecto de la implementación del modelo de aprendizaje automático en el rendimiento de las redes de telecomunicaciones de la ciudad de Nauta?	Objetivo General: Optimizar el rendimiento de las redes de telecomunicaciones en la ciudad de Nauta mediante la aplicación de aprendizaje automático, con la finalidad de mejorar la eficiencia, estabilidad y calidad del servicio de Internet. Objetivo Específico 1: Identificar las principales limitaciones técnicas y operativas de las redes de telecomunicaciones de la ciudad de Nauta mediante el análisis de indicadores de rendimiento como latencia, ancho de banda y pérdida de paquetes. Objetivo Específico 2: Evaluar la precisión del modelo de aprendizaje automático Random Forest para anticipar eventos de congestión en la red de telecomunicaciones de la ciudad de Nauta. Objetivo Específico 3: Determinar el efecto de la implementación del modelo de aprendizaje automático en el rendimiento de la red mediante la comparación de los indicadores de latencia, ancho de banda y pérdida de paquetes antes y después de su aplicación.	Hipótesis General: La aplicación del aprendizaje automático optimiza significativamente el rendimiento de las redes de telecomunicaciones en la ciudad de Nauta, mejorando la eficiencia, estabilidad y calidad del servicio de Internet. Hipótesis Específica 1: Las redes de telecomunicaciones de la ciudad de Nauta presentan limitaciones técnicas y operativas reflejadas en altos niveles de latencia, limitado ancho de banda y elevada pérdida de paquetes antes de la implementación del modelo de aprendizaje automático. Hipótesis Específica 2: El modelo de aprendizaje automático Random Forest presenta un alto nivel de precisión para anticipar eventos de congestión en las redes de telecomunicaciones de la ciudad de Nauta. Hipótesis Específica 3: La implementación del modelo de aprendizaje automático mejora significativamente el rendimiento de las redes de telecomunicaciones de la ciudad de Nauta, reduciendo la latencia y la pérdida de paquetes, además de incrementar el ancho de banda disponible.	Variable Independiente (X): Aplicación del aprendizaje automático para optimización de redes de telecomunicaciones. Variable Dependiente (Y): Rendimiento de las redes de telecomunicaciones.	Dimensión: Modelo predictivo de congestión mediante Random Forest. Dimensión: Modelo predictivo de congestión. Indicadores: Accuracy, Recall, F1-Score, Índice Kappa. Dimensión: Calidad de servicio de red (QoS). Indicadores: Latencia promedio, ancho de banda promedio, pérdida de paquetes. Dimensión: Calidad de servicio de red (QoS). Indicadores: Latencia promedio, ancho de banda promedio, pérdida de paquetes.	Accuracy, Recall, F1-Score, Índice Kappa. Porcentaje de precisión y coeficiente de concordancia. Milisegundos, Mbps, porcentaje de pérdida de paquetes. Diferencia pretest-posttest en ms, Mbps y porcentaje	Tipo: Aplicada. Diseño: Preexperimental con pretest y posttest. Enfoque: Cuantitativo. Técnica: Monitoreo de red. Instrumento: Software de monitoreo de red. Análisis: Estadística descriptiva. Técnica: Evaluación del modelo ML. Instrumento: Módulo de validación Random Forest. Análisis: Métricas de clasificación. Técnica: Monitoreo comparativo. Instrumento: Software de monitoreo de red. Análisis: Prueba de Wilcoxon.