

ESCUELA POLITÉCNICA NACIONAL

**FACULTAD DE DE INGENIERÍA ELÉCTRICA Y
ELECTRÓNICA**

ANÁLISIS EN PON Y MACHINE LEARNING EN REDES ÓPTICAS

**REVISIÓN DE TÉCNICAS DE MACHINE LEARNING EN REDES
ÓPTICAS**

**TRABAJO DE INTEGRACIÓN CURRICULAR PRESENTADO COMO
REQUISITO PARA LA OBTENCIÓN DEL TÍTULO DE INGENIERA EN
TELECOMUNICACIONES**

GENESIS MADELAINE VILLA IMBACUÁN

genesis.villa@epn.edu.ec

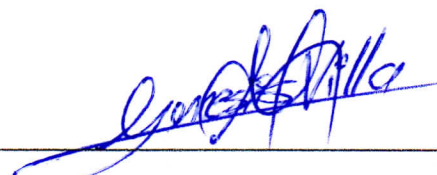
DIRECTOR: MSc. CHRISTIAN JOSÉ TIPANTUÑA TENELEMA

christian.tipantuna@epn.edu.ec

DMQ, abril 2023


CERTIFICACIONES

Yo, GENESIS MADELAINE VILLA IMBACUÁN declaro que el trabajo de integración curricular aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.



GENESIS MADELAINE VILLA IMBACUÁN

Certifico que el presente trabajo de integración curricular fue desarrollado por GENESIS MADELAINE VILLA IMBACUÁN, bajo mi supervisión.



MSc. CHRISTIAN JOSE TIPANTUÑA TENELEMA
DIRECTOR DEL TRABAJO DE TITULACIÓN

DECLARACIÓN DE AUTORÍA

A través de la presente declaración, afirmamos que el trabajo de integración curricular aquí descrito, así como el (los) producto(s) resultante(s) del mismo, son públicos y estarán a disposición de la comunidad a través del repositorio institucional de la Escuela Politécnica Nacional; sin embargo, la titularidad de los derechos patrimoniales nos corresponde a los autores que hemos contribuido en el desarrollo del presente trabajo; observando para el efecto las disposiciones establecidas por el órgano competente en propiedad intelectual, la normativa interna y demás normas.

GENESIS MADELAINE VILLA IMBACUÁN

MSc. CHRISTIAN JOSÉ TIPANTUÑA TENELEMA

DEDICATORIA

Le dedico el resultado de este trabajo con todo mi cariño y amor a:

A DIOS quien me dio la oportunidad de vivir y ha sido mi guía y fortaleza hasta el día de hoy.

A mi madre Mirian, quien con su amor, paciencia y apoyo incondicional me ha permitido llegar a cumplir un objetivo más de mi vida. Aunque hemos pasado momentos difíciles, gracias por inculcar en mí, el ejemplo de esfuerzo, perseverancia y valentía para seguir adelante a pesar de las adversidades.

A mi padre Jhonny, que desde el cielo me cuida e ilumina mi camino para seguir con mis proyectos.

A mi hermano Israel por brindarme consejos y palabras de aliento durante todo este proceso, te quiero mucho.

Finalmente, quiero dedicar esta tesis a todas aquellas personas que estuvieron a mi lado apoyándome y lograron que este sueño se haga realidad.

AGRADECIMIENTO

Mi profundo agradecimiento a DIOS, quien con su amor y bendición llena siempre mi vida.

Deseo expresar mi gratitud a toda mi familia por creer en mí y estar siempre presentes.

De igual manera, mis agradecimientos a la Escuela Politécnica Nacional, a la Facultad de Eléctrica y Electrónica, a mis profesores, quienes con la enseñanza de sus valiosos conocimientos me ayudaron a crecer como persona y de manera profesional.

Finalmente, quiero expresar mis más grandes y sinceros agradecimientos al Dr. Christian Tipantuña y Dr. Danny Guamán, principales soportes durante todo este proceso, quienes con su conocimiento, dirección y tiempo dedicado me ayudaron en el desarrollo de este proyecto.

ÍNDICE DE CONTENIDO

CERTIFICACIONES	I
DECLARACIÓN DE AUTORÍA	II
DEDICATORIA	III
AGRADECIMIENTO	IV
ÍNDICE DE CONTENIDO	VI
RESUMEN	VII
ABSTRACT	VIII
1 INTRODUCCIÓN	1
1.1 Objetivo general	2
1.2 Objetivos específicos	2
1.3 Alcance	2
1.4 Marco teórico	3
1.4.1 Motivación para la aplicación de aprendizaje automático en Networking	3
1.4.2 Motivación para la aplicación de aprendizaje automático en Redes Ópticas	6
1.4.3 Métodos de Aprendizaje Automático	9
1.4.4 Desafíos en Redes Ópticas resueltos con Machine Learning	17
2 METODOLOGÍA	20
2.1 Planificación (Planning)	21
2.1.1 Alcance de los antecedentes del estudio	21
2.1.2 Estrategia de búsqueda de artículos	22
2.1.3 Procedimiento de inclusión y exclusión	23
2.1.4 Esquema de clasificación y extracción de datos	27
2.2 Realización (Conducting)	29
2.3 Presentación (Reporting)	38
3 RESULTADOS, CONCLUSIONES Y RECOMENDACIONES	39
3.1 Resultados	39
3.1.1 RQ1—¿Cuáles son las técnicas de ML utilizadas para resolver los problemas reportados en [2], [6], [7] relacionados con el funcionamiento y operación de redes ópticas?	39

3.1.2	RQ2—¿Qué desafíos informados en [2], [6], [7] han sido mayoritaria- mente abordados mediante el uso de las técnicas de ML reportadas?	43
3.1.3	RQ3—¿Qué datasets que han sido utilizados por las técnicas de ML en los artículos revisados están disponibles?	49
3.1.4	RQ4—¿Cuál es el nivel de madurez de las técnicas de ML identificadas?	50
3.1.5	Discusión	54
3.2	Conclusiones	58
3.3	Recomendaciones	59
4	REFERENCIAS BIBLIOGRÁFICAS	61
5	ANEXOS	I
I	ANEXO I: Base de datos y documentos generados en la etapa de planificación.	I
II	ANEXO II: ID de técnicas de ML vs Problema en redes ópticas abordado . . .	II
III	ANEXO III: ID de desafíos en redes óptica vs Técnica de ML empleada . . .	III

RESUMEN

No hay duda alguna que durante la última década, las redes ópticas se han convertido en “redes inteligentes”. Las redes definidas por software (SDN), redes ópticas definidas por software (SDON), redes ópticas elásticas (EON), son algunas tecnologías emergentes que proporcionan una base para innovaciones prometedoras en el funcionamiento y operación de redes ópticas. Los algoritmos de aprendizaje automático, están brindando la posibilidad de desarrollar cada vez más esta área de estudio prometedora. Puesto que el aprendizaje automático, puede aprender de una gran cantidad de datos disponibles de los elementos de la red, encontrar una solución adecuada ante cualquier tipo de escenario y así crear redes más dinámicas y flexibles que mejoren la experiencia de los usuarios. Esta investigación, realiza un estudio de mapeo sistemático que proporciona una visión general sobre aprendizaje automático en redes ópticas, identifica sus oportunidades y sugiere futuras líneas de investigación. El estudio analizó 96 artículos de las 841 publicaciones obtenidas sobre esta temática, con el objetivo de encontrar información acerca del uso de técnicas de aprendizaje automático para resolver problemas relacionados con el funcionamiento y operación de redes ópticas. Se concluye que, las técnicas de aprendizaje automático supervisado, son aquellas que mayoritariamente se utilizan para la administración de recursos, monitoreo de red, gestión de fallas y clasificación y predicción de tráfico de una red óptica. Sin embargo, se necesitan solventar ciertos desafíos para que exista un despliegue exitoso de este tipo de métodos en sistemas de comunicaciones reales, ya que la mayoría de las investigaciones, se las ha realizado en entornos experimentales controlados.

PALABRAS CLAVE: Redes Ópticas, Aprendizaje Automático, Mapeo Sistemático.

ABSTRACT

There is no doubt that, during the last decade, optical networks have become "smart networks", software defined networks (SDN), software-defined optical networks (SDON), elastic optical networks (EON), are some emerging technologies that provide a basis for promising innovations in the functioning and operation of optical networks. Machine learning algorithms are providing the possibility to develop this promising study area. Since machine learning can learn from a large amount of data available from the elements of the network. They can find a suitable solution for any type of environment and thus create more dynamic and flexible networks that improve the user experience. This investigation carries out a systematic mapping that provides an overview about machine learning in optical networks, identifies its opportunities, and suggests future research lines. The study analyzed 96 papers from the 841 publications obtained on this topic, with the objective of finding information about the use of machine learning techniques to solve problems related to the functioning and operation of optical networks. It is concluded that supervised machine learning techniques are those that are mostly used for resource management, network monitoring, fault management and classification and traffic prediction of an optical network. However, certain challenges need to be solved for a successful deployment of this type of methods in real communication systems, since most of the research has been carried out in controlled experimental environments.

KEYWORDS: Optical Networks, Machine Learning, Systematic Mapping.

1 INTRODUCCIÓN

En la actualidad, la gran cantidad de datos heterogéneos generados día a día, la capacidad computacional disponible para el usuario final (principalmente en términos de RAM y CPU), el acceso a distintos tipos de información e implementación (librerías) de técnicas como el algoritmo del descenso del gradiente, han impulsado que el aprendizaje automático (ML: Machine Learning) se pueda aplicar en distintas áreas de trabajo. Las máquinas entrenadas con ML, ahora son capaces de realizar actividades intelectuales que tradicionalmente eran solo resueltas por los seres humanos, encontrando en corto tiempo, la solución a un problema específico [1].

El campo de las redes de comunicaciones, no ha quedado exento de la incorporación de soluciones basadas en ML para la optimización del rendimiento de procesos, tales como, estimación de parámetros de calidad o de tráfico [2]. Sin embargo, la explotación de técnicas y soluciones de ML en este campo, todavía se encuentra en sus inicios. Por lo que la presente investigación, a través de una revisión sistemática de la literatura existente, busca contribuir al estado del arte en cuanto al uso de ML para futuros estudios o implementaciones en los sistemas y redes de comunicaciones, específicamente en el área de redes ópticas. Las redes ópticas constituyen la infraestructura física básica de todas las redes de grandes proveedores a nivel mundial. Esto a consecuencia de sus propiedades únicas (por ejemplo: alta capacidad, bajo costo, etc.) y a que no hay señales del surgimiento de una nueva tecnología que la sustituya en un futuro cercano [1].

El presente Trabajo de Integración Curricular, como punto de partida, describe la motivación para la aplicación de ML en networking y en específico en redes ópticas, ya que existen diversas formas en que un sistema de inteligencia artificial (ML), pueda mejorar la gestión de una red. De manera adicional, se presenta una breve descripción de los aspectos generales de ML y de sus categorías, incluyendo el aprendizaje supervisado, no supervisado, semi-supervisado y reforzado. Posterior a ello, se define de manera general las diferentes áreas de trabajo en las que se podría aplicar técnicas de ML en redes ópticas. Finalmente, en base a la revisión sistemática de la literatura existente, se analiza y clasifica el uso de técnicas de ML aplicadas para resolver problemas relacionados con el funcionamiento y operación de redes ópticas (por ejemplo: administración de recursos, monitoreo de red, gestión de fallas, clasificación y predicción de tráfico). Este estudio, pretende ser una referencia académica para futuras contribuciones en el campo de los sistemas de comunicaciones y redes ópticas.

1.1 OBJETIVO GENERAL

Realizar una revisión sistemática de la literatura existente acerca del uso de técnicas de aprendizaje automático aplicadas para resolver problemas relacionados con el funcionamiento y operación de redes ópticas.

1.2 OBJETIVOS ESPECÍFICOS

1. Revisar el fundamento teórico asociado a las técnicas de aprendizaje automático y las áreas de trabajo en las que se podría aplicar ML en redes ópticas.
2. Aplicar una metodología de investigación sistemática para la revisión de la literatura existente acerca del uso de técnicas de aprendizaje automático para resolver problemas relacionados con el funcionamiento y operación de redes ópticas.
3. Clasificar la información obtenida de acuerdo con problemas relacionados con el funcionamiento y operación de redes ópticas y sus soluciones basadas en técnicas de aprendizaje automático.
4. Determinar el nivel de madurez de las técnicas de aprendizaje automático para solventar problemas relacionados con el funcionamiento y operación de redes ópticas.

1.3 ALCANCE

El presente Trabajo de Integración Curricular, tiene como objetivo realizar una revisión sistemática de la literatura existente acerca del uso de técnicas de ML aplicadas para resolver problemas relacionados con el funcionamiento y operación de redes ópticas. Inicialmente, se desarrollará una fase teórica en donde se detallan las motivaciones de la aplicación de técnicas de ML en el área de networking y en específico en redes ópticas. De manera adicional, se describe de forma breve en qué consisten las técnicas de ML, haciendo énfasis en los algoritmos de aprendizaje supervisado, no supervisado, semi-supervisado y reforzado. Para finalizar el análisis teórico, se realiza una definición general de las áreas de trabajo en las que se podría aplicar técnicas de ML en redes ópticas y en las que se enfocará el presente componente: administración de recursos, enrutamiento y asignación de longitud de onda, monitoreo de red, predicción de tráfico, clasificación de tráfico, control de conges-

ción, gestión de fallas, gestión de QoS^[1], gestión de QoE^[2] y estimación de QoT^[3], que han sido tomadas como referencia de los artículos [2], [6], [7], ya que se evidencia que estas áreas son las de mayor interés de estudio en el dominio de redes ópticas.

Posterior a la finalización del análisis teórico, se inicia la etapa de exploración de la literatura existente. Esta última, se la realiza mediante la recolección de información con respecto al tema de técnicas de ML en redes ópticas empleando una metodología de investigación que permita realizar un proceso de mapeo sistemático de la literatura. Luego, se organiza la información codificada en base a los problemas reportados en [2], [6], [7] (administración de recursos, enrutamiento y asignación de longitud de onda, monitoreo de red, predicción de tráfico, clasificación de tráfico, control de congestión, gestión de fallas, gestión de QoS, gestión de QoE y estimación de QoT), asociando a cada área de trabajo, los algoritmos de ML con los que se podría mejorar su desempeño. De manera adicional, se definirá el detalle de madurez de las técnicas de ML reportadas, para así contribuir al estado del arte para estudios futuros.

1.4 MARCO TEÓRICO

1.4.1 MOTIVACIÓN PARA LA APLICACIÓN DE APRENDIZAJE AUTOMÁTICO EN NETWORKING

Desde principios del siglo XXI, el trabajo de los administradores de red se ha vuelto cada vez más complicado. La llegada de las máquinas virtuales, cloud computing, el Internet de las cosas (IoT: Internet of Things), la transmisión de video en vivo, etc., causan que monitorear y controlar las redes de comunicaciones sea cada vez más complejo. Sin embargo, existe la posibilidad que muchas de estas tareas puedan ser simplificadas, automatizadas y organizadas mediante inteligencia artificial (AI: Artificial Intelligence) y técnicas de ML [8].

La AI es un campo de estudio que otorga a las computadoras una inteligencia similar a la de una persona cuando realizan una tarea, ayudando así a tomar decisiones rápidas y

^[1] QoS: La calidad de servicio (en inglés Quality of Service, QoS) es un conjunto de tecnologías que funcionan en una red para controlar el tráfico y garantizar el rendimiento de aplicaciones críticas con capacidad de red limitada [3].

^[2] QoE: La calidad de experiencia (en inglés Quality of Experience, QoE) es una medida de cuán satisfechos están los usuarios con un servicio digital, como una aplicación, un servicio de transmisión de video o un sitio web. Es aquella que brinda información sobre cómo los usuarios perciben la QoS [4].

^[3] QoT: La calidad de transmisión (en inglés Quality of Transmission, QoT) es una medida que representa el rendimiento de un canal de transmisión, misma que es utilizada para evaluar la disponibilidad de una conexión en un sistema de comunicación [5].

adecuadas que permitan la automatización de procesos. En tanto que, ML es una rama derivada de la inteligencia artificial, que se centra en la programación de computadoras para resolver problemas sin la participación humana [8].

A medida que las redes de comunicaciones se vuelven más complejas y distribuidas, los beneficios de implementar la tecnología AI/ML en redes, son cada vez más evidentes. AI/ML puede ser utilizado para acelerar la resolución de problemas, responder a dificultades en tiempo real, predecir contrariedades antes de que estas ocurran e inclusive, existe la posibilidad de aumentar la información de seguridad de las redes al mejorar la respuesta y mitigación de amenazas [9]. Si bien hay muchas formas en que un sistema AI/ML mejora el desempeño de una red, en un sentido general, las motivaciones para la aplicación de ML en networking se pueden analizar en cuatro campos, como se presentan en la Figura 1.1.

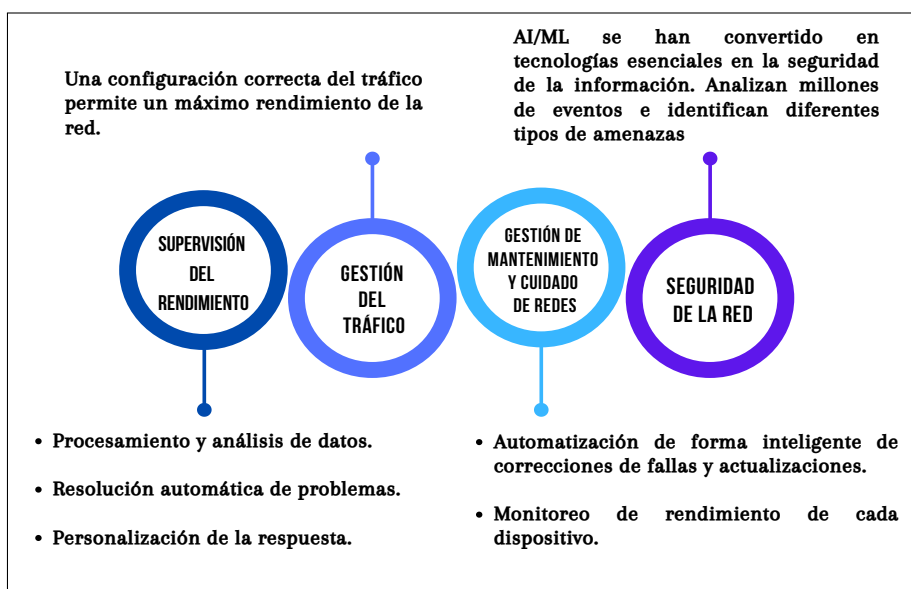


Figura 1.1: Motivación para la aplicación de ML en networking.

1.4.1.1 Supervisión del rendimiento

AI/ML ha comenzado a formar parte de los monitores de rendimiento de red (NPM: Network Performance Monitor). Los NPMs son softwares de monitoreo diseñados para reducir las interrupciones en la red y mejorar su rendimiento través de una recopilación de información detallada de todos los dispositivos que la componen [10]. Aunque esta tecnología no es ampliamente utilizada en la actualidad, las organizaciones son cada vez más conscientes de los beneficios que posee su incorporación, tales como:

- ❑ **Procesamiento y análisis de datos:** Las redes manipulan una gran cantidad de datos día a día, por lo que es necesario contar con sistemas que permitan procesar y

comprender esta información heterogénea. La AI tiene la capacidad de clasificar estas grandes cantidades de datos y analizarlas en tiempo real. Mientras que, ML examina datos históricos y los compara con los analizados para definir algún tipo de tendencia de red. Así, en un futuro, se puede reconocer de manera rápida cualquier problema que se suscite en la red, sin la necesidad de un análisis profundo [8].

- ❑ **Resolución automática de problemas:** Con el uso de AI/ML existe la posibilidad de aprender y eliminar los problemas comunes que afectan a una red. Mediante una recopilación de información a medida que un problema ocurre repetidamente, se puede descubrir cómo resolverlo sin la necesidad de intervención humana [8].
- ❑ **Personalización de la respuesta:** AI/ML no funcionan por sí solos, se requiere de un proceso de preparación previa para lograr obtener los resultados deseados. Por lo que es posible realizar un entrenamiento personalizado de las técnicas de ML empleadas, para que estas puedan responder a diferentes tipos de eventos [8].

1.4.1.2 Gestión del tráfico

La gestión del tráfico y la supervisión del rendimiento se encuentran estrechamente vinculadas. Los servicios de gestión de tráfico analizan el flujo de paquetes a través de los dispositivos de red. Mientras que los sistemas de rendimiento de red, se basan en informes de estado de esos mismos dispositivos [11]. Una configuración correcta del tráfico, puede ayudar a los administradores de red a aprovechar al máximo el rendimiento del sistema.

Las herramientas de ML ayudan con la gestión del tráfico en todo momento. Una vez que las herramientas identifican cuando el tráfico aumenta en algunas rutas y en otras no fluye, estas pueden enviar respuestas de manera automática o manuales para corregir los errores encontrados [12].

Adicionalmente, las herramientas de ML pueden predecir tendencias de tráfico, ayudando a la toma de decisiones futuras. Cuantas más herramientas de ML sean incorporadas a los segmentos de una red, más detallados pueden ser sus análisis y recomendaciones [12].

1.4.1.3 Gestión de mantenimiento y cuidado de redes

Una red debe ser segura, por lo tanto, su mantenimiento continuo es muy importante. En muchos de los casos, las organizaciones no pueden realizar un mantenimiento regular, ya que resulta demasiado complejo y con períodos de inactividad que generan pérdidas de capital, por lo que no pueden garantizar un adecuado funcionamiento de la red. ML es

capaz de detectar cuándo un componente de red se encuentra en etapas iniciales de falla y predecir cuándo aparecerán nuevas fallas en los nodos que actualmente se encuentran en buen estado [12]. Al hacer uso de técnicas de AI/ML, el mantenimiento puede realizarse de dos formas [8]:

- ❑ **Automatización de forma inteligente de correcciones de fallas y actualizaciones:** Se emplea análisis predictivos para establecer una ventana de mantenimiento personalizada que evita la interrupción del servicio.
- ❑ **Monitoreo de rendimiento de cada dispositivo:** Se detecta cuándo los servicios comienzan a presentar fallas o usan un mayor procesamiento de lo habitual, permitiendo resolver estos problemas antes de que causen un gran impacto en la red.

1.4.1.4 Seguridad de la red

Balbix, una empresa líder en ciberseguridad, manifiesta que la AI y ML se han convertido en tecnologías de gran importancia en la seguridad de la información, ya que analizan rápidamente millones de eventos e identifican diferentes tipos de amenazas. Estas tecnologías aprenden con el tiempo, basándose en el pasado para identificar nuevos tipos de ataques [13]. Con el uso de ML es posible detectar con mayor facilidad ataques como, phishing ^[4] de correo electrónico, descarga de código malicioso, compromiso de cuentas, ataques de capa 7 en aplicaciones web y compromiso de red a nivel de sistema operativo [8]. Una correcta detección de anomalías en el comportamiento de una red, ayuda a los equipos de seguridad de la red a identificar todo tipo de evento, desde un nodo de hardware comprometido hasta un empleado deshonesto en la red de la empresa [13].

1.4.2 MOTIVACIÓN PARA LA APLICACIÓN DE APRENDIZAJE AUTOMÁTICO EN REDES ÓPTICAS

Con el rápido desarrollo del Internet, los sistemas de comunicaciones cada día se vuelven mucho más complejos. Las redes ópticas, que juegan un papel importante tanto en el núcleo como en las redes de acceso en un sistema de comunicación, también enfrentan grandes desafíos de complejidad y operación [15]. Para superar estas limitaciones y abordar problemas a futuro, se necesita implementar una mayor capacidad de inteligencia en los sistemas ópticos, que permitan operaciones de red autónomas y flexibles [16]. Se ha demostrado

^[4] Phishing: Es un tipo de fraude en línea que consiste en engañar a las personas para que proporcionen información confidencial, como contraseñas o números de tarjetas de crédito, haciéndose pasar por una fuente confiable [14].

que las técnicas de AI y ML brindan la posibilidad de resolver problemas complejos y, por lo tanto, la posibilidad de optimizar la eficiencia de los sistemas ópticos a través de un mejor desempeño en las tareas de asignación del espectro, predicción de tráfico, clasificación de tráfico, QoT, entre otros parámetros. A continuación, se analizan los 4 factores que impulsan la aplicación de ML en redes ópticas, los mismos se resumen en la Figura 1.2.

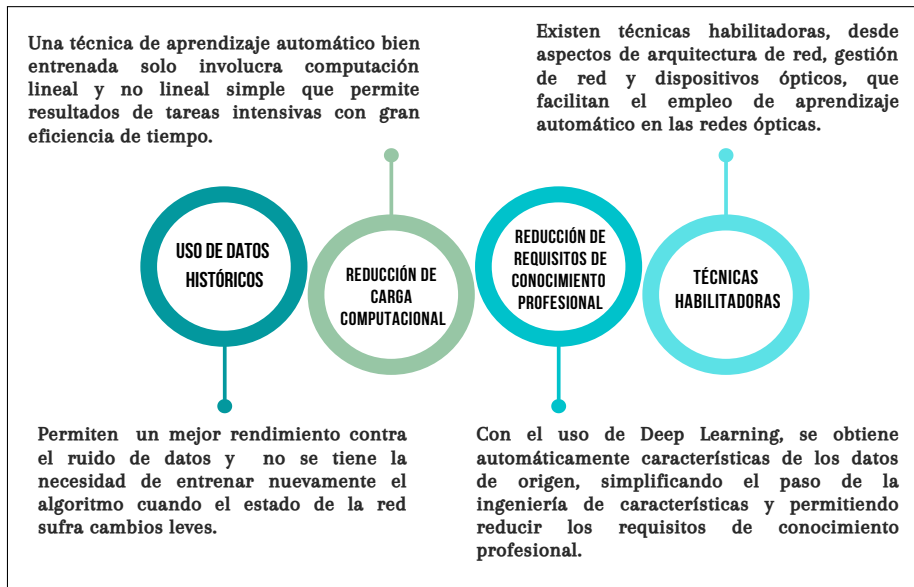


Figura 1.2: Motivación para la aplicación de ML en redes ópticas.

1.4.2.1 Uso de datos históricos

Actualmente, diversos tipos de datos estadísticos sobre la gestión y el control de una red óptica pueden ser recolectados en los sistemas. Por lo que saber la manera correcta de manipular estos datos para optimizar el rendimiento de la red, se convierte en un requisito importante. Los métodos tradicionales como la estimación bayesiana o métodos heurísticos, por lo general, solo explotan el estado actual de la red óptica ya que no cuentan con el uso de información histórica, generando degradaciones en el rendimiento del sistema cuando hay la presencia de ruido o errores en las muestras que se emplean. Si se hace uso de técnicas de ML, se entrena al modelo con un conjunto de datos que contiene información histórica y este aprende la relación existente en el conjunto de datos. Como resultado, el método basado en ML logra un mejor rendimiento contra el ruido de datos y no es necesario entrenar nuevamente el algoritmo cuando el estado de la red sufra cambios leves [2].

1.4.2.2 Reducción de carga computacional

Debido al desarrollo de las redes 5G, el tráfico de datos se vuelve cada vez más dinámico y heterogéneo. Para cumplir con los diferentes niveles de QoS, la reconfiguración flexible es

fundamental en redes ópticas futuras. Sin embargo, los métodos tradicionales (analíticos y heurísticos) hacen uso de una gran carga computacional. Lo que en consecuencia, genera tiempos de procesamiento excesivos cuando se presenta una reconfiguración de red extensa y, por lo tanto, estos métodos no son convenientes de emplear para operaciones de red en tiempo real. El uso de una técnica de ML bien entrenada, solo involucra computación lineal y no lineal simple, que permiten resultados de tareas complejas con gran eficiencia de tiempo, optimizando así el funcionamiento de redes ópticas [2].

1.4.2.3 Reducción de requisitos de conocimiento profesional

En ciertas tareas de redes ópticas, los métodos analíticos no han sido analizados completamente. Por lo tanto, se desconoce qué información existe en aquellos datos sin procesar. Lo que causa un desperdicio de recursos humanos en el procesamiento de datos, ya que la ingeniería de características ^[5] no se encuentra dirigida [2]. Con el uso de aprendizaje profundo (DL: Deep Learning), se pueden obtener automáticamente características de los datos de origen, simplificando el paso de la ingeniería de características, con lo cual, se reducen los requisitos de conocimiento profesional [18]. Por ejemplo, en el monitoreo de la relación señal óptica a ruido (OSNR: Optical Signal to Noise Ratio) con diagrama de ojo ^[6], no existe una relación explícita entre los píxeles en los diagramas de ojo y el valor de OSNR, por lo que la capacidad del método analítico es limitada. Sin embargo, con DL los datos sin procesar se ingresan en la red neuronal y las características encontradas se extraen automáticamente de la información analizada [20].

1.4.2.4 Técnicas habilitadoras

Además de las grandes ventajas que proporciona el uso ML, existen técnicas que abarcan aspectos de arquitectura de red, gestión de red y dispositivos ópticos, que facilitan el empleo de ML en redes ópticas. Desde el punto de vista de la arquitectura de red, la red óptica definida por software (SDON: Software Defined Optical Network) ofrece las capacidades de redes ópticas totalmente programables y reconfigurables que aumentan la flexibilidad operativa [21]. Desde el aspecto de la gestión de red y la recolección de datos, con la ayuda de la arquitectura de red SDON, los datos monitoreados y la configuración de la red se

^[5] Ingeniería de características: Proceso de seleccionar, manipular y transformar datos sin procesar, en características que sean posibles utilizar para el entrenamiento y la predicción en técnicas de ML [17].

^[6] Diagrama de ojo: Método utilizado para el análisis del comportamiento de los enlaces de transmisión. Permite evaluar el ruido de canal y la interferencia entre símbolos a través de las formas de onda de los pulsos que se propagan en un enlace de comunicaciones [19].

transmiten en dirección norte-sur y luego, se forma un bucle de administración en la red óptica que es importante para las aplicaciones de ML [2]. Con respecto a los dispositivos ópticos, las técnicas de procesamiento de señales ópticas se encuentran en desarrollo, permitiendo que el conocimiento acerca de estos sistemas, sea más eficiente y exacto [22].

1.4.3 MÉTODOS DE APRENDIZAJE AUTOMÁTICO

ML es un área de investigación que se encarga de enseñar a las máquinas a realizar una actividad similar a la mente humana. Aunque su capacidad cognitiva es mucho más limitada que la del ser humano, pueden procesar grandes cantidades de información en corto tiempo y obtener información útil [23]. A continuación, se proporciona una breve descripción de los cuatro algoritmos de aprendizaje automático más populares: aprendizaje supervisado, aprendizaje no supervisado, aprendizaje semi-supervisado y aprendizaje reforzado.

1.4.3.1 Aprendizaje supervisado

El aprendizaje supervisado es una subcategoría de AI/ML, que emplea conjuntos de datos etiquetados para entrenar algoritmos que clasifican información o predicen resultados con precisión. A medida que los datos de entrada ingresan en el modelo, este ajusta sus pesos hasta que el algoritmo opere de manera correcta [24]. El aprendizaje automático supervisado, se utiliza si se conoce previamente que es lo que se desea enseñar a una máquina [25]. Se requiere exponer al algoritmo a un gran conjunto de datos de entrenamiento, permitir que el modelo examine la salida y ajustar los parámetros hasta obtener los resultados deseados. El algoritmo mide su precisión a través de una función de pérdida, ajustándose hasta que el error se ha minimizado lo suficiente. Finalmente, se prueba la máquina entrenada permitiéndole realizar predicciones para un conjunto de datos de validación, es decir, nuevos datos no vistos [24], [25]. El aprendizaje supervisado se puede clasificar en dos tipos de algoritmos: clasificación y regresión, como se presenta en la Figura 1.3.

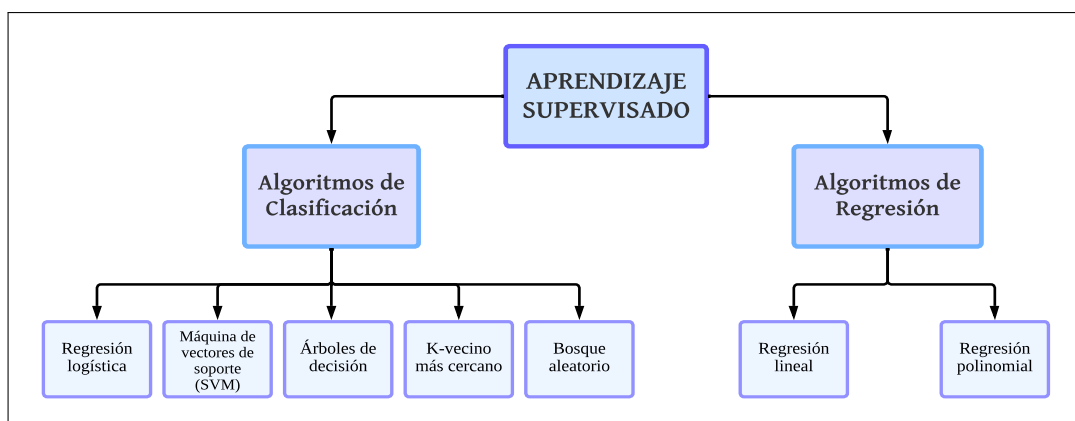


Figura 1.3: Algoritmos de aprendizaje supervisado.

1.4.3.1.1 Algoritmos de clasificación

Los algoritmos de clasificación pueden explicar o predecir un valor de clase. Es decir, utilizan un algoritmo para asignar en categorías específicas, los datos de prueba [23]. La clasificación reconoce asociaciones específicas dentro del conjunto de datos analizados, e intenta obtener conclusiones sobre cómo se deben etiquetar y caracterizar esas entidades. Los algoritmos de clasificación comunes son: los clasificadores lineales, máquinas de vectores de soporte (SVM: Support Vector Machines), árboles de decisión, k-vecinos más cercano y bosque aleatorio, que se describen a continuación.

- ❑ **Regresión logística:** Es el algoritmo de clasificación más simple y básico, suena como un método de regresión, pero no lo es. La regresión logística estima la probabilidad de que ocurra un evento en función de una o más entradas [26]. La regresión logística, se utiliza cuando la variable dependiente tiene dos salidas, es decir, “verdadero” y “falso” o “sí” y “no” . Se usa principalmente para resolver problemas de clasificación binaria, como la identificación de spam [24].
- ❑ **Máquina de vectores de soporte (SVM):** Es un modelo de aprendizaje supervisado que se utiliza tanto para la clasificación como para la regresión de datos. Este algoritmo construye un hiperplano donde la distancia entre dos clases de puntos de datos es máxima. El hiperplano se conoce como “límite de decisión” y separa las clases de puntos de datos, a cada lado del plano [24].
- ❑ **Árboles de decisión:** Es un modelo de aprendizaje supervisado en el que los datos analizados, se distribuyen continuamente de acuerdo con un parámetro determinado. El árbol de decisión está constituido por dos entidades: nodos de decisión y hojas. Las hojas son las decisiones o los resultados finales. Mientras que los nodos de decisión, son el punto en donde se dividen los datos [27].
- ❑ **K-vecino más cercano:** Es un modelo de aprendizaje supervisado que clasifica los puntos de datos en función de su proximidad y asociación con otros datos disponibles. Este algoritmo busca calcular la distancia entre los puntos de datos, generalmente a través de la distancia euclidiana. Y luego, asigna una clase en función de la categoría o promedio más frecuente [24].
- ❑ **Bosque aleatorio:** Es un modelo de aprendizaje supervisado que se utiliza tanto para la clasificación como para la regresión de datos. El “bosque” es la representación de una colección de árboles de decisión no correlacionados, que luego se fusionan para reducir la varianza y crear predicciones de datos más precisas [24].

1.4.3.1.2 Algoritmos de regresión

Los métodos de regresión se definen como un proceso para encontrar las correlaciones entre las variables dependientes e independientes [28]. Permite predecir o explicar un valor numérico particular en función de un conjunto de datos anteriores. La regresión lineal y la regresión polinomial son los algoritmos más populares de este tipo [24].

- ❑ **Regresión lineal:** Es el algoritmo de regresión más simple. Se lo utiliza para para identificar la relación entre una variable dependiente y una o más variables independientes, permitiendo realizar predicciones sobre resultados futuros [24]. La regresión lineal se acopla a una línea recta o superficie, minimizando las diferencias entre los valores de salida previstos y reales [29].
- ❑ **Regresión polinomial:** Es un algoritmo de regresión en la que la relación entre las variables independientes y las variables dependientes, se modelan a través de un polinomio de grado n . Es un caso especial de regresión lineal, donde se ajusta la ecuación polinomial en los datos con una relación curvilínea entre las variables dependientes e independientes [30].

1.4.3.2 Aprendizaje no supervisado

El aprendizaje no supervisado es una subcategoría de AI/ML, que permite que una máquina explore un conjunto de datos sin la necesidad de supervisar el modelo. Es decir, su proceso de entrenamiento es un juego de datos sin etiquetas o clases previamente definidas [31]. Después de la exploración de los datos iniciales, el algoritmo intenta identificar patrones que relacionen diferentes variables para descubrir información oculta que antes no se detectaba, basándose únicamente en propiedades estadísticas [25]. Los algoritmos de aprendizaje no supervisados se dividen en: agrupación (clustering), asociación y reducción de dimensionalidad, como se presenta en la Figura 1.4.

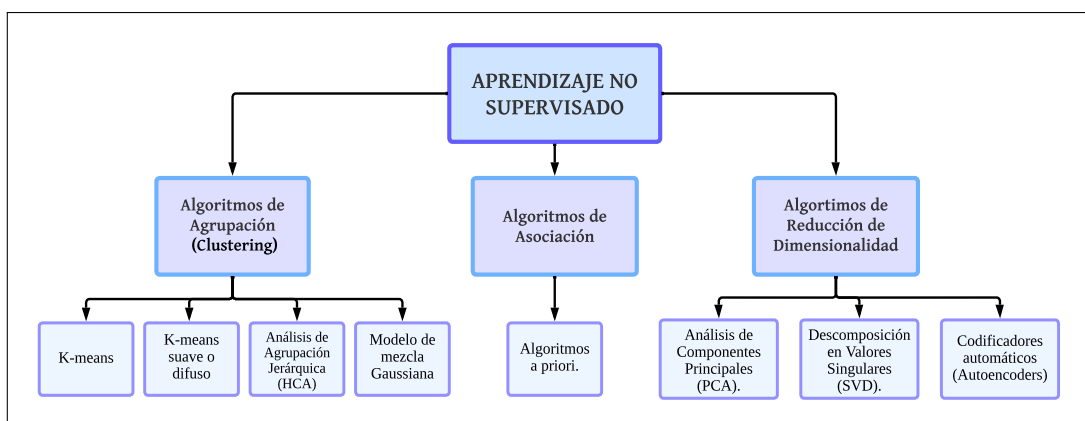


Figura 1.4: Algoritmos de aprendizaje no supervisado.

1.4.3.2.1 Algoritmos de agrupación

Agrupación (Clustering) es una técnica que trata principalmente de encontrar una estructura o patrón en una colección de datos no etiquetados, en función de sus similitudes o diferencias [32]. Los algoritmos de agrupación más comunes son: K-means, K-means suave o difuso, Análisis de Agrupación Jerárquica (HCA: Hierarchical Cluster Analysis) y el modelo de mezcla Gaussiana.

- ❑ **K-means:** Es un algoritmo que divide el conjunto de datos analizados en subgrupos distintos no superpuestos (clústeres) predefinidos por K, donde cada punto de datos pertenece a un solo grupo. K-means intenta hacer que los puntos de datos dentro del clúster sean lo más similares posible, y al mismo tiempo, trata de mantener los clústeres lo más diferentes posible [33].
- ❑ **K-means suave o difuso** Es un algoritmo similar a K-means. Su única diferencia es que, en lugar de asignar un punto exclusivamente a un solo grupo (clúster), puede haber algún tipo de borrosidad o superposición entre dos o más grupos [34]. Es decir, los puntos de datos pueden pertenecer a múltiples grupos con distintos grados de pertenencia [35].
- ❑ **Análisis de Agrupación Jerárquica (HCA):** Es un algoritmo que tiene por objetivo asociar elementos o registros que están “cerca” entre sí, formando agrupaciones jerárquicas. Puede trabajar de dos formas: aglomerante o divisiva. En la agrupación aglomerante, sus puntos de datos se aíslan inicialmente y luego se fusionan iterativamente según su similitud hasta que se logra un grupo. La agrupación divisiva, se puede definir como lo opuesto a la agrupación aglomerante. En este caso, un solo grupo de datos se divide en función de las diferencias entre los puntos de datos analizados [35].
- ❑ **Modelo de mezcla Gaussiana:** Es un algoritmo que se emplea para clasificar los datos en diferentes categorías según la distribución de probabilidad. Supone que todos los puntos de datos se generan a partir de una combinación de distribuciones gaussianas con parámetros desconocidos [36].

1.4.3.2.2 Algoritmos de asociación

Los algoritmos de asociación son técnicas basadas en reglas que permiten encontrar relaciones no obvias entre variables en un conjunto de datos determinado. Por lo que puede considerarse como una herramienta de análisis de datos [32]. Los algoritmos a priori son

los más utilizados dentro de esta clasificación.

- ❑ **Algoritmos a priori:** Son técnicas que siguen una secuencia de pasos para encontrar el conjunto de elementos más frecuente en la base de datos dada. Se utilizan dentro de conjuntos de datos transaccionales para identificar conjuntos de elementos frecuentes o colecciones de elementos. Es decir, determina la probabilidad de consumir un producto, dado el consumo de otro producto [35].

1.4.3.2.3 Algoritmos de reducción de dimensionalidad

Aunque una mayor cantidad de datos permite generar resultados mucho más precisos, también puede afectar el rendimiento de los algoritmos de ML. Los algoritmos de reducción de dimensionalidad, son técnicas que se emplean cuando el número de características en un conjunto de datos determinado es muy alto. Durante su funcionamiento, estos algoritmos reducen la cantidad de entradas de datos a un tamaño adecuado y al mismo tiempo preservan la integridad del conjunto de datos [35]. Los algoritmos de reducción de dimensionalidad más comunes son: los de Análisis de Componentes Principales (PCA: Principal Component Analysis), Descomposición en Valores Singulares (SVD: Singular Value Decomposition) y Codificadores automáticos (Autoencoders).

- ❑ **Análisis de Componentes Principales (PCA):** Es un algoritmo que se utiliza para reducir redundancias y comprimir conjuntos de datos a través de la extracción de características. Utiliza transformaciones lineales para crear nuevas representaciones de datos, generando conjuntos de “componentes principales” [35].
- ❑ **Descomposición en Valores Singulares (SVD):** Es un algoritmo que factoriza una matriz principal en tres matrices de bajo rango. Se usa comúnmente para reducir el ruido y comprimir datos, por ejemplo, archivos de imagen [35].
- ❑ **Codificadores automáticos:** Son algoritmos que aprovechan las redes neuronales para comprimir datos y luego recrear una nueva representación de la entrada de datos original [35].

1.4.3.3 Aprendizaje semi-supervisado

El aprendizaje semi-supervisado es una subcategoría de AI/ML, que combina técnicas de aprendizaje no supervisado y supervisado. Durante la etapa de entrenamiento, en lugar de agregar etiquetas a todo el conjunto de datos analizados, se revisa y se etiqueta a mano solo una pequeña parte de los datos para entrenar un modelo. Finalmente, este modelo entrenado, permite realizar una clasificación correcta de características de un conjunto de

datos sin etiquetar de mayor tamaño [37]. El aprendizaje semi-supervisado interrelaciona el aprendizaje no supervisado y el aprendizaje supervisado para resolver los desafíos clave que implica el uso independiente de cada una de estas técnicas. A diferencia del aprendizaje no supervisado, el aprendizaje semi-supervisado funciona para una variedad de problemas de clasificación, regresión, agrupación y hasta asociación. A diferencia del aprendizaje supervisado, el aprendizaje semi-supervisado emplea pequeñas cantidades de datos etiquetados y grandes cantidades de datos no etiquetados, que permiten reducir capacidad computacional y acortar el tiempo de preparación de datos [38]. Las técnicas de aprendizaje semi-supervisado comúnmente empleadas son: auto-entrenamiento (self-training), co-entrenamiento (co-training) y con propagación de etiquetas basada en gráficos, como se presenta en la Figura 1.5.

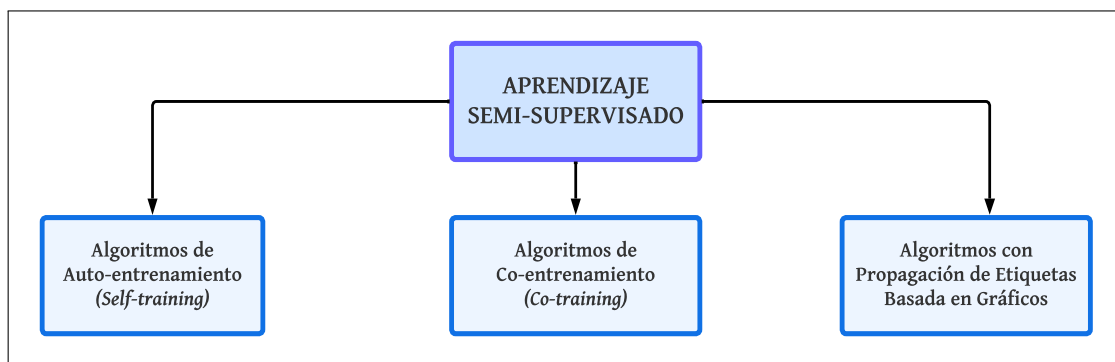


Figura 1.5: Algoritmos de aprendizaje semi-supervisado.

1.4.3.3.1 Algoritmos de auto-entrenamiento

El auto-entrenamiento (self-training) es una de las técnicas más simples de aprendizaje semi-supervisado. Se puede escoger cualquier técnica de aprendizaje supervisado de clasificación o regresión y modificarla para que funcione de forma semi-supervisada. Sin embargo, se debe enfatizar que el rendimiento de estos algoritmos puede variar de un conjunto de datos a otro, y en muchos casos, el auto-entrenamiento posee un rendimiento menor en comparación con una técnica supervisada [38].

1.4.3.3.2 Algoritmos de co-entrenamiento

El co-entrenamiento (co-training) es una técnica derivada de los algoritmos de autoentrenamiento. Se utiliza cuando solo se dispone de un pequeño conjunto de datos etiquetados. Durante su etapa inicial, se entrena a dos clasificadores individuales en función de dos vistas de datos. Las vistas de datos son diferentes conjuntos de características que brindan información adicional sobre cada etapa, lo que significa que son independientes dada la clase [38]. El co-entrenamiento es ideal en tareas de clasificación de contenido web.

1.4.3.3 Algoritmos con propagación de etiquetas basada en gráficos

Una de las formas más populares de emplear técnicas de aprendizaje semi-supervisado, es representar datos etiquetados y no etiquetados en forma gráfica. Para luego aplicar un algoritmo de propagación de etiquetas que difunda la información a través de toda la red de datos. El uso práctico de este método, permite predecir los intereses de los clientes en función de la información sobre otros clientes. Por ejemplo, si dos personas están conectadas en las redes sociales, es muy probable que compartan intereses similares [38].

1.4.3.4 Aprendizaje reforzado

El aprendizaje reforzado es una subcategoría de AI/ML, que permite que una máquina interactúe con un entorno. Un agente aprende a comportarse en un medio, realizando las acciones y viendo los resultados de las acciones. Por cada buena acción, el agente recibe una retroalimentación positiva, y por cada mala acción, el agente recibe una retroalimentación negativa o penalización. Al repetir el proceso miles de veces, la máquina eventualmente puede aprender de su experiencia [25].

El aprendizaje reforzado se diferencia del aprendizaje supervisado en que, en el aprendizaje supervisado, los datos de entrenamiento tienen la clave de la respuesta. Por lo que el modelo se entrena con la solución correcta. Mientras que, en el aprendizaje por refuerzo no hay respuesta, pero el agente de refuerzo decide qué hacer para responder o realizar una determinada tarea. En comparación con el aprendizaje no supervisado, el aprendizaje por refuerzo es bastante diferente en términos de objetivos [39]. Hay tres enfoques para implementar un algoritmo de aprendizaje reforzado:

- ❑ **Basado en valores:** En un método de aprendizaje reforzado basado en valores, se intenta maximizar una función de valor $V(s)$ [39].
- ❑ **Basado en políticas:** En un método de aprendizaje reforzado basado en políticas, se intenta desarrollar una política tal que la acción realizada en cada estado, permita obtener la máxima recompensa en el futuro. Los métodos deterministas y los métodos estocásticos son ejemplos de aprendizaje reforzado basado en políticas [39].
- ❑ **Basado en modelos:** En un método de aprendizaje reforzado basado en modelos, se debe crear un modelo virtual para cada entorno. El agente aprende a actuar en ese entorno específico [39].

En base a los enfoques descritos anteriormente, existen tres tipos de algoritmos o métodos de aprendizaje reforzado: aprendizaje reforzado positivo, aprendizaje reforzado negativo y

aprendizaje reforzado profundo, tal como se muestra en la Figura 1.6.

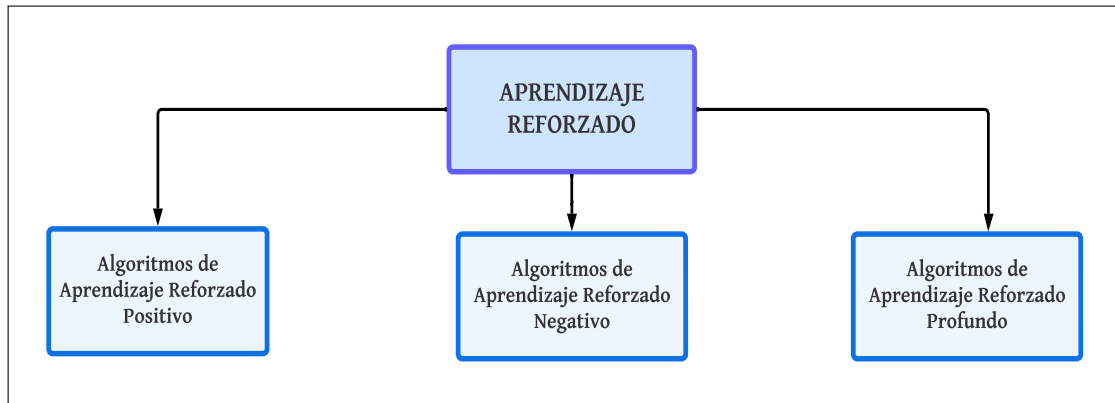


Figura 1.6: Algoritmos de aprendizaje reforzado.

1.4.3.4.1 Algoritmos de aprendizaje reforzado positivo

El aprendizaje reforzado positivo se define como un evento que ocurre debido a un comportamiento específico. Aumenta la fuerza y la frecuencia del comportamiento e impacta de manera positiva en la acción tomada por el agente. Este tipo de algoritmo ayuda a maximizar el rendimiento y mantener el cambio durante un período prolongado. Sin embargo, puede causar una optimización excesiva del estado y afectar los resultados [39].

1.4.3.4.2 Algoritmos de aprendizaje reforzado negativo

El aprendizaje reforzado negativo se define como un comportamiento que se produce debido a una condición negativa, que debería haberse evitado o detenido. Este tipo de algoritmo ayuda a determinar el estándar mínimo de rendimiento. El refuerzo negativo puede ser una herramienta eficaz cuando se usa correctamente. Sin embargo, es posible que su uso no siempre obtenga los resultados esperados, ya que puede reforzar comportamientos favorables o desfavorables [39].

1.4.3.4.3 Algoritmos de aprendizaje reforzado profundo

El aprendizaje reforzado profundo, combina el aprendizaje por refuerzo y el aprendizaje profundo. Es una nueva generación de las técnicas de ML, que se caracteriza en la toma de decisiones por ensayo y error, para que una máquina pueda aprender a realizar una tarea específica. El aprendizaje reforzado profundo está conformado por un agente inteligente que aprende a optimizar un proceso de decisión. Si el resultado de esa decisión es favorable, el agente automáticamente repetirá esa decisión en el futuro. Mientras que si el resultado es perjudicial, evitará volver a tomar la misma decisión [40].

1.4.4 DESAFÍOS EN REDES ÓPTICAS RESUELTOS CON MACHINE LEARNING

Según [2], [6], [7], las áreas de trabajo con mayor interés de estudio en las que se podría aplicar técnicas de ML para solventar problemas relacionados con el funcionamiento y operación de redes ópticas son:

- ❑ **Administración de recursos (Resource Management):** La administración de recursos permite crear un método efectivo para analizar el tráfico que recorre a través de una red. Así, se reduce el tiempo de inactividad, errores y otros problemas que se puedan suscitar, permitiendo satisfacer las necesidades de los usuarios y dispositivos al mismo tiempo. La administración de recursos de red es comparable a la creación de carriles exclusivos para el tráfico. Los recursos se pueden asignar de manera diferente para cada carril de la red. Al configurar carriles de red donde los recursos se distribuyen de acuerdo con la necesidad real, aumenta la eficiencia en el procesamiento de paquetes de red [41], [42].
- ❑ **Enrutamiento y asignación de longitud de onda (RWA):** El problema de enrutamiento y asignación de longitud de onda considera una red donde las solicitudes (es decir, caminos de luz) se pueden transportar en diferentes longitudes de onda ópticas a través de la red. A cada solicitud aceptada, se le asigna una ruta desde su origen hasta su destino, así como una longitud de onda específica. Los caminos de luz enrutados sobre el mismo enlace deben asignarse a diferentes longitudes de onda. Mientras que los caminos de luz cuyos recorridos pertenecen a enlaces separados, pueden usar la misma longitud de onda [43].
- ❑ **Monitoreo de red (Network Monitoring):** El monitoreo de una red implica la gestión de los enlaces entre dispositivos, estaciones de trabajo, servidores, dispositivos virtuales y dispositivos móviles. Con el fin de identificar la congestión, maximizar y mejorar el rendimiento de la red para el usuario. Con el uso de herramientas de monitoreo de red automatizadas, los analistas pueden recopilar datos, identificar, medir, realizar evaluaciones de rendimiento y diagnosticar problemas de una determinada red. Las herramientas de monitoreo, recopilan datos de fuentes como el protocolo SNMP, datos de flujo, captura de paquetes y dispositivos de infraestructura de red, para que su rendimiento y disponibilidad puedan analizarse y en última instancia, maximizarse [44], [45].
- ❑ **Predicción de tráfico (Traffic Prediction):** La predicción del tráfico de red tiene como objetivo predecir el tráfico de red posterior, utilizando los datos de tráfico de red

anteriores. Lo que puede servir como un enfoque proactivo para la administración de redes, tareas de planificación, procesos de seguridad, evitar la congestión y aumentar la velocidad de las redes. Por lo que se ha convertido actualmente, en un tema de interés para la comunidad informática. Una predicción rápida del tráfico, permite a los administradores de red tomar medidas tempranas para controlar la carga de tráfico y evitar el estado de congestión de una red [46], [47].

- ❑ **Clasificación de tráfico (Traffic Classification):** La clasificación de tráfico ofrece la capacidad de reconocer automáticamente la aplicación que ha generado un determinado flujo de paquetes, a partir de la observación directa y pasiva de los paquetes individuales, o flujo de paquetes que fluyen en la red. Cada clase de tráfico identificada puede tratarse de manera diferente, resultando fundamental para una serie de actividades que son de interés para los operadores, proveedores de servicios de Internet y administradores de red en general. La clasificación del tráfico con precisión, es de suma importancia en las actividades de la red, tales como, la supervisión de la seguridad, la ingeniería del tráfico, la detección de fallas, la contabilidad del uso de la red, entre otros. [48], [49].
- ❑ **Control de congestión (Congestion Control):** Se utiliza el término control de congestión, para describir los esfuerzos realizados por los nodos de la red para prevenir o responder a condiciones de sobrecarga. Debido a que la congestión generalmente resulta ser un gran problema, el objetivo fundamental de una red es hacer que la congestión disminuya o prevenirla. Lo que podría lograrse persuadiendo a algunos hosts para que dejen de enviar paquetes de información en la red, mejorando así, la situación para todos los demás. Sin embargo, es más común que los mecanismos de control de la congestión se caractericen por ser equitativos. Es decir, traten de compartir el conflicto de sobrecarga entre todos los usuarios que pertenecen a la red, en lugar de causar un problema a unos pocos. Por lo que muchos mecanismos de control de congestión, tienen algún tipo de asignación de recursos incorporado [50].
- ❑ **Gestión de fallas (Fault Management):** La gestión de fallas es un componente de fundamental importancia en la administración de una red. Al resolver en corto tiempo las fallas detectadas, minimiza el tiempo de inactividad y evita contratiempos en los dispositivos, garantiza una disponibilidad óptima de la red y disminución de pérdidas comerciales [51].
- ❑ **Gestión de QoS y QoE (QoS and QoE Management):** Es necesario aclarar la diferencia existente entre la calidad de servicio (QoS) y la calidad de experiencia (QoE).

El primer término, se relaciona con el proceso de gestión de los recursos de la red, como por ejemplo: reducción de pérdida de paquetes, latencia, inestabilidad de la red, etc. La QoS se encarga de asignar recursos a los distintos tipos de datos que transitan por la red, en función de diversos niveles de prioridad. El segundo término, es una medida del nivel general de satisfacción del cliente con un proveedor de red. Dado que QoE representa QoS desde el punto de vista del usuario, QoE es una extensión de QoS. Debido a las limitaciones que giran en torno a las redes de telecomunicaciones, existen restricciones en las estrategias de red para la gestión de recursos, dificultando alcanzar el nivel óptimo de QoE y QoS al mismo tiempo [52].

- **Estimación de QoT (QoT estimation):** La calidad de la transmisión es aquel parámetro que depende tanto de la naturaleza del medio que lo rodea como de la naturaleza de la señal. La naturaleza del medio es directamente proporcional a la calidad de la transmisión. Es decir, si el ancho de banda del medio es alto, se transmitirán señales de buena calidad. Y si la calidad de una señal es buena, la transmisión es fluida y exitosa. Actualmente, lograr estimar la QoT de un camino de luz antes de su despliegue, es un paso de fundamental importancia para un diseño optimizado de redes ópticas [53], [54].

2 METODOLOGÍA

El presente Trabajo de Integración Curricular, realiza un estudio de mapeo ^[1] sistemático de la literatura existente acerca de técnicas y soluciones de ML para resolver problemas relacionados con el funcionamiento y operación de redes ópticas. Es decir, pretende ofrecer una visión global acerca de este tema de actualidad. La metodología consta de tres etapas [55]: planificación (planning), realización (conducting) y presentación (reporting), cuyo flujo de procesos y tareas desarrolladas, se presentan de manera general en la Figura 2.1.

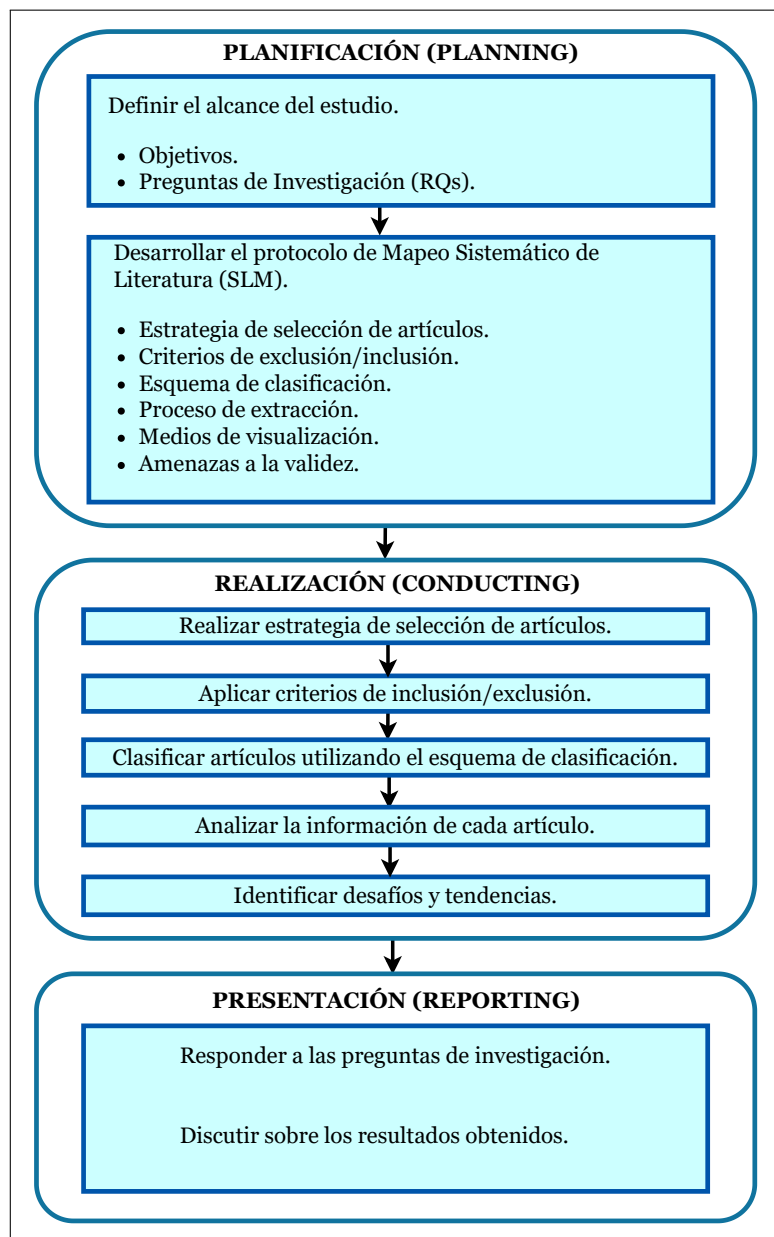


Figura 2.1: Flujo de proceso y tareas del estudio de mapeo sistemático, basado en [56].

^[1] Estudio de mapeo: Enfoque sistemático para proporcionar una visión general de un área de interés de investigación. Muestra evidencias cuantitativas, para identificar tendencias [55].

2.1 PLANIFICACIÓN (PLANNING)

El presente trabajo adoptó un enfoque cuantitativo. Debido a que recolectará, clasificará y representará de manera gráfica, información obtenida acerca del uso de técnicas de ML para resolver problemas relacionados con el funcionamiento y operación de redes ópticas. Durante esta etapa de planificación, se desarrollan 5 tareas que permiten cumplir con los dos primeros objetivos específicos descritos en este estudio.

2.1.1 ALCANCE DE LOS ANTECEDENTES DEL ESTUDIO

Esta tarea consta de dos secciones. En la primera sección, se describe el background de la investigación a ser realizada. Es decir, se abordan temas relacionados con la motivación del uso de ML en networking y en redes ópticas, conceptos de ML y descripción de áreas de trabajo en las que se podría aplicar técnicas de ML en redes ópticas, evidenciándose en el Capítulo 1. En la segunda sección, se definen las preguntas de investigación que permitirán cumplir con éxito los objetivos planteados en este trabajo, mismas que son descritas en la Tabla 2.1.

Tabla 2.1: Preguntas de Investigación (RQs) planteadas.

N°	Pregunta de Investigación (RQ)	Justificación de la RQ
RQ1	¿Cuáles son las técnicas de ML utilizadas para resolver los problemas reportados en [2], [6], [7] relacionados con el funcionamiento y operación de redes ópticas?	Saber qué técnicas de ML son utilizadas para resolver los problemas reportados en [2], [6], [7] relacionados con el funcionamiento y operación de redes ópticas, es la piedra angular de este proyecto. Ya que permite proporcionar una visión general de esta área de investigación e identificar sus brechas.
RQ2	¿Qué desafíos informados en [2], [6], [7] han sido mayoritariamente abordados mediante el uso de las técnicas de ML reportadas?	El objetivo de la investigación es obtener conocimiento acerca de cuáles son los desafíos informados en [2], [6], [7] relacionados con el funcionamiento y operación de redes ópticas, que han sido mayoritariamente abordados mediante las técnicas de ML identificadas.
RQ3	¿Los datasets que han sido utilizados por las técnicas de ML en los artículos revisados están disponibles?	Tener conocimiento acerca de la disponibilidad de información de los datasets empleados por las técnicas de ML en los artículos revisados, brinda la posibilidad de crear un repositorio conjunto de datos para que puedan ser utilizados por quienes los necesiten y se encuentren en casos similares en futuras investigaciones.
RQ4	¿Cuál es el nivel de madurez de las técnicas de ML identificadas?	Utilizando la literatura existente, se asigna un nivel de madurez a las técnicas de ML identificadas en el estudio, para poder reconocer brechas y tendencias de este tema. La información obtenida, puede ser valiosa para futuras investigaciones.

2.1.2 ESTRATEGIA DE BÚSQUEDA DE ARTÍCULOS

En esta tarea, se utiliza una estrategia de recopilación de información empleando la base de datos de Scopus, para encontrar literatura de investigación de alta calidad. Se decide emplear esta plataforma, ya que indexa artículos de las principales bibliotecas digitales utilizadas en el área de investigación que es de interés para este trabajo, incluidos IEEE Xplore, Springer Link, Science Direct o ACM [57]. A partir de Scopus, se crea una cadena de búsqueda que abarque la mayor cantidad de posibilidades de temas relacionados con la investigación realizada, en este caso: "Aprendizaje Automático" y "Redes Ópticas". Por lo tanto, la cadena de búsqueda final obtenida es:

TITLE-ABS-KEY (("Machine Learning") AND ("Optical Communication"
OR "Optical Network"))

Con esta cadena de búsqueda, se obtuvieron inicialmente 841 contribuciones relacionadas a la temática de estudio. Sin embargo, para asegurarse que la cadena definida es la correcta, que no se están omitiendo artículos que pueden ser de importancia durante la investigación y validar la integridad de las contribuciones proporcionadas a partir de Scopus (Amenazas a la validez), el experto en temas de ML y redes ópticas, provee un conjunto de artículos de prueba relacionados con el tema de investigación (Tabla 2.2).

Tabla 2.2: Artículos del Conjunto de Prueba.

N°	Título	Autor	1° Iteración (Final)
1	A QoT prediction technique based on machine learning and NLSE for QoS and new lightpaths in optical communication networks	Yongfeng FU, Jing CHEN, Weiming WU, Yu HUAN2, Jie HONG, Long CHEN, Zhongbin LI	Si
2	An Overview on Application of Machine Learning Techniques in Optical Networks	Francesco Musumeci, Cristina Rottondi, Avishek Nag, Irene Macaluso, Darko Zibar, Marco Ruffini, Massimo Tornatore	Si
3	A Tutorial on Machine Learning for Failure Management in Optical Networks	Francesco Musumeci, Cristina Rottondi, Giorgio Corani, Shahin Shahkarami, Filippo Cugini, and Massimo Tornator	Si
4	Machine learning for intelligent optical networks: A comprehensive survey	Rentao Gu, Zeyuan Yang, Yuefeng Ji	Si
5	Overview on routing and resource allocation-based machine learning in optical networks	Yongjun Zhang, Jingjie Xin, Xin Li*, Shanguo Huang	Si
6	Autonomous Operations in Optical Networks	Alba P. Vela, Marc Ruiz, and Luis Velasco	Si

Tabla 2.2 – continuación de la página anterior.

N°	Título	Autor	1° Iteración (Final)
7	Examples of Machine Learning Algorithms for Optical Network Control and Management	Alba P. Vela, Marc Ruiz, and Luis Velasco	Si
8	DeepALM: Holistic Optical Network Monitoring based on Machine Learning	Joo Yeon Cho, Jose-Juan Pedreno-Manresa, Sai Kireet Patri, Khouloud Abdelli, Carsten Tropschug, Jim Zou, Piotr Rydlichowski	Si
9	Machine Learning Applications for Short Reach Optical Communication	Yapeng Xie, Yitong Wang, Sithamparanathan Kandeepan and Ke Wang	Si
10	Machine learning for quality of transmission: a picture of the benefits fairness when planning WDM networks	Matteo Lonardi, Jelena Pestic, Thierry Zami, Emmanuel Seve, Nicola Rossi	Si
Tasa de Éxito:			10/10

Estos documentos que de manera independiente son proporcionados por el tutor, tienen como objetivo principal su revisión dentro de la lista de artículos extraídos en Scopus. Si la mayoría de ellos consta dentro de los resultados obtenidos, significa que la cadena de búsqueda definida es la adecuada. Caso contrario, se requiere de su redefinición cuantas veces sea necesaria, en base a ciertas características (títulos, key words, etc.) de los artículos que no han sido encontrados en los resultados de Scopus, para evitar omitir contribuciones que pueden proporcionar información valiosa en la investigación. En este proyecto, los artículos de prueba con los que se validó la cadena obtuvieron una tasa de éxito elevada en la primera iteración, sin la necesidad de desarrollar más, ni modificar la cadena de búsqueda planteada inicialmente.

2.1.3 PROCEDIMIENTO DE INCLUSIÓN Y EXCLUSIÓN

Además de la creación de la cadena de búsqueda, es necesario realizar una identificación de criterios de inclusión y exclusión de artículos de manera automatizada y manual, que permitan lograr una recopilación de información adecuada. Los criterios de inclusión y exclusión se utilizan para excluir estudios que no son relevantes para responder a las preguntas de investigación (RQs).

2.1.3.1 Inclusión-exclusión automatizada

Los criterios de inclusión y exclusión automatizada, son aquellos filtros que pueden ser aplicados directamente a través de herramientas y funciones online que poseen las plataformas que están sirviendo como base de datos, en este caso, Scopus. Los criterios que han sido seleccionados para esta investigación, han sido definidos a partir de estudios de mapeo sis-

temáticos similares como [56]. Todos los siguientes criterios de inclusión deben cumplirse, para que un artículo pase a un filtrado manual.

1. **Tipo de documento:** Las contribuciones que forman parte de este estudio son documento de conferencia y artículos. Porque son aquellos documentos que pueden aportar datos actualizados y relevantes respecto a un tema de investigación.
2. **Idioma:** Los artículos que son tomados en cuenta para el presente estudio, deben estar escritos en inglés. Ya que este es el idioma universal empleado para la transmisión y entendimiento de nuevos conocimientos alrededor del mundo.

De las 841 contribuciones obtenidas inicialmente, al aplicar los criterios de inclusión-exclusión automatizada en la plataforma de Scopus, los resultados se redujeron a 831 artículos.

2.1.3.2 Inclusión-exclusión manual

Los criterios de inclusión y exclusión manual son aquellos filtros aplicados por decisiones tomadas por los propios investigadores del estudio. Para tener en claro que tipos de criterios se requieren tomar en cuenta en esta etapa, se realiza un árbol de decisión. Para esta investigación, este árbol puede ser visualizado en la Figura 2.2.

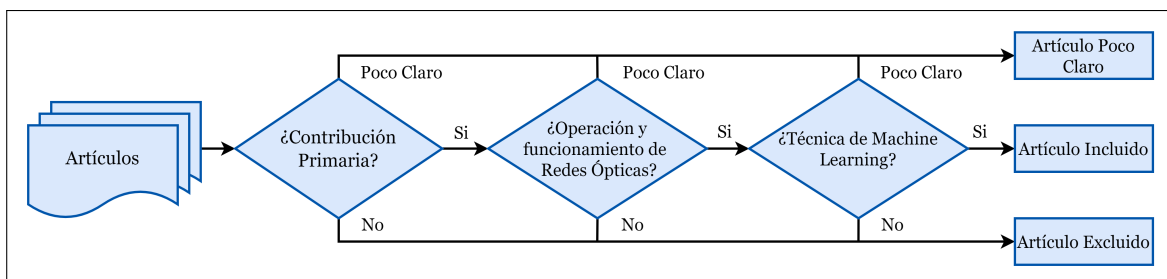


Figura 2.2: Árbol de decisión para la selección manual de artículos, basado en [56].

La Figura 2.2 describe los procesos de decisión que deben tomarse en cuenta para la selección manual de artículos que serán analizados en este estudio. De las 831 contribuciones obtenidas a partir del proceso de filtrado automatizado, se requiere determinar si los artículos son contribuciones primarias [2], pertenecen al dominio de redes ópticas y están relacionados con técnicas de ML. Si la contribución cumple con las 3 características principales definidas en el árbol de decisión, automáticamente pasa a ser un artículo incluido para su posterior codificación. Por otra parte, si el artículo no cumple con alguna de las carac-

[2] Contribución Primaria: Son fuentes en donde la información proporcionada ha sido publicada por primera vez, resultado de un trabajo intelectual sobre un tema de investigación. Proviene de una fuente directa, sea una persona, institución u otro medio [58], [59].

terísticas del árbol de decisión, queda excluido. Finalmente, si existen dudas para clasificar algún trabajo, se lo puede marcar como "Poco Claro". Así, el artículo puede ser analizado de manera posterior y decidir si incluirlo o no en el grupo de artículos a ser codificados.

A partir del árbol de decisión, la lista de criterios de inclusión-exclusión manual utilizados para evaluar los artículos durante esta investigación, se incluye en la Tabla 2.3. Todos los criterios deben cumplirse para la inclusión de un artículo, pero si algún criterio de exclusión se cumple, la contribución se excluye.

Tabla 2.3: Criterios de inclusión y exclusión manual.

Criterios	Descripción
Criterios de Inclusión	<ol style="list-style-type: none"> 1. El artículo es una contribución primaria. 2. La contribución reportada en el artículo está relacionada con el funcionamiento y operación de redes ópticas. 3. El artículo incluye al menos una contribución que proponga una técnica de ML aplicada a la resolución de algún problema reportado en [2], [6], [7].
Criterios de Exclusión	<ol style="list-style-type: none"> 1. El trabajo reporta una contribución secundaria o terciaria ^[3]. 2. La contribución no se centra en el funcionamiento y operación de redes ópticas. 3. La contribución reportada aborda algún problema reportado en [2], [6], [7], pero no emplea una técnica de ML.

Durante esta etapa de filtrado manual, se realizan dos fases de clasificación de artículos. La primera, se la conoce como una fase piloto. Cuyo objetivo es alinear los criterios entre tutor y estudiante. La segunda, es denominada como la fase principal. La cual consiste en una selección basada en los títulos y resúmenes de los artículos, para finalizar con una selección basada en el texto completo. Todas estas etapas, son realizadas a través de CADIMA (<https://www.cadima.info/>).

CADIMA, es una herramienta web gratuita que facilita la organización, realización, y asegura la documentación de revisiones sistemáticas, mapas sistemáticos y revisiones bibliográficas adicionales [60]. Es la única herramienta de acceso abierto que está diseñada para: (1) ayudar a lo largo del proceso de estudios sistemático, (2) ser adecuada para utilizarla en revisiones sistemáticas más amplias que las ciencias médicas, (3) permitir la extracción de datos offline y (4) apoyar a trabajos como equipo de revisión. CADIMA, garantiza una documentación completa de todo el proceso realizado en los estudios sistemáticos y permite

^[3] Contribución Secundaria o Terciaria: Las fuentes secundarias son aquellas que poseen información primaria, sintetizada y reorganizada. Permiten conocer hechos a partir de datos recopilados por otros. Mientras que, las fuentes terciarias recopilan y resumen variadas fuentes primarias y secundarias para proveer una mirada general de un determinado tema de investigación [58], [59].

que los resultados de la revisión estén disponibles públicamente. Es decir, los documentos pueden estar disponibles para terceros si así lo acuerda el equipo de trabajo que lo esté utilizando en sus investigaciones [61].

Los detalles de las dos fases de clasificación manual de artículos para esta investigación, se presentan a continuación:

2.1.3.2.1 Fase piloto

- ❑ La fase piloto es un proceso n-iterativo de clasificación de artículos, que se realiza hasta alcanzar un coeficiente de fiabilidad de 0,8 (alfa de Krippendorff ^[4]) entre tutor y estudiante [64].
- ❑ A partir de un conjunto de 5 artículos aleatorios del grupo de 831 contribuciones, tutor y estudiante individualmente leen las secciones de título y resumen de los artículos y los clasifican en incluido, excluido o poco claro.
- ❑ Si al finalizar la clasificación de los artículos, no se ha obtenido un coeficiente de fiabilidad mayor o igual a 0.8, tutor y estudiante discuten los resultados obtenidos para armonizar sus criterios de clasificación antes de la siguiente iteración. En esta investigación, luego de la tercera iteración realizada, se logró obtener un coeficiente de fiabilidad de 0.94.

2.1.3.2.2 Fase principal

- ❑ La fase principal consiste en dos etapas de clasificación manual de artículos. En la primera etapa, se seleccionan contribuciones basadas en sus títulos y resúmenes. En la segunda etapa, se seleccionan contribuciones basadas en su texto completo.
- ❑ En la primera etapa, los evaluadores (tutor y estudiante) trabajan individualmente leyendo los títulos y resúmenes de los trabajos y marcándolos como incluidos, excluidos o poco claros. En este estudio, 167 contribuciones (20 %) son revisadas por los dos investigadores a cargo de la investigación. Al existir más de un evaluador, se puede evitar la exclusión de contribuciones que pueden aportar información relevante a este estudio, mejorando los resultados en la clasificación de artículos. Mientras que los

^[4] Coeficiente alfa de Krippendorff (α): Es una medida estadística del grado de acuerdo entre codificadores y los investigadores, lo utilizan regularmente en el campo del análisis de contenido. Sus valores van de -1 a 1, donde 1 representa un acuerdo unánime entre los evaluadores, 0 indica que están adivinando al azar y los valores negativos sugieren que los evaluadores están sistemáticamente en desacuerdo [62], [63].

664 artículos restantes (80 %) son analizados exclusivamente por el estudiante. Las divergencias encontradas en la clasificación de artículos son discutidas y resueltas por el tutor y estudiante en reuniones planificadas. Al finalizar esta etapa, se cuentan con 223 artículos seleccionados.

- En la segunda etapa, los evaluadores (tutor y estudiante) leen los artículos seleccionados en la primera etapa, a nivel de detalle. Es decir, se analiza primero el título, luego el resumen y finalmente las conclusiones. Sin embargo, si esta información no es clara, se pueden considerar otras partes del documento (por ejemplo: introducción, títulos de sección y subsección). En esta etapa, los 223 artículos solo se pueden clasificar entre incluidos o excluidos. Similar como en la primera etapa, 45 contribuciones (20 %) son revisadas por el tutor y el estudiante a cargo de la investigación, con el objetivo de lograr mejores resultados en la clasificación de artículos. Al existir más de un evaluador, se puede evitar la exclusión de contribuciones que pueden aportar información relevante a este estudio. Mientras que los 178 artículos restante (80 %), son analizados exclusivamente por el estudiante. Las divergencias encontradas en la clasificación de artículos, son discutidas y resueltas por el tutor y estudiante en reuniones planificadas.

Luego de concluir con el proceso de inclusión- exclusión manual, se cuentan con 96 artículos para el proceso de codificación.

2.1.4 ESQUEMA DE CLASIFICACIÓN Y EXTRACCIÓN DE DATOS

El esquema de clasificación es una herramienta que permite extraer de manera organizada la información relevante de cada uno de los artículos seleccionados, permitiendo así, contestar a las preguntas de investigación (RQs) planteadas con anterioridad.

En este trabajo, una parte del esquema se lo elabora a partir de clasificaciones existentes y descritas en el Capítulo 1 de este proyecto. Por ejemplo, hay diversos tipos de clasificaciones de técnicas de ML previamente establecidas y existen diferentes áreas de trabajo relacionadas con el funcionamiento y operación de redes ópticas. Estas guías, brinda una reducción del tiempo empleado en la elaboración del esquema, puesto que no es necesario empezarlo desde cero. Luego, este esquema se lo completa y perfecciona, fusionando o agregando nuevas categorías (por ejemplo: nuevas técnicas de ML, fusionando áreas de trabajo de redes ópticas en un solo desafío) o dividiendo categorías en subcategorías (por ejemplo: clasificación y subclasificación de técnicas de ML). Con el objetivo principal de

obtener de los artículos, la mayor cantidad de datos posibles que permitan contestar las preguntas de investigación, no excluir información importante para el estudio, y a su vez, tratar de no extraer datos innecesarios que no aporten información relevante. El esquema de clasificación para esta investigación, se visualiza en la Figura 2.3.

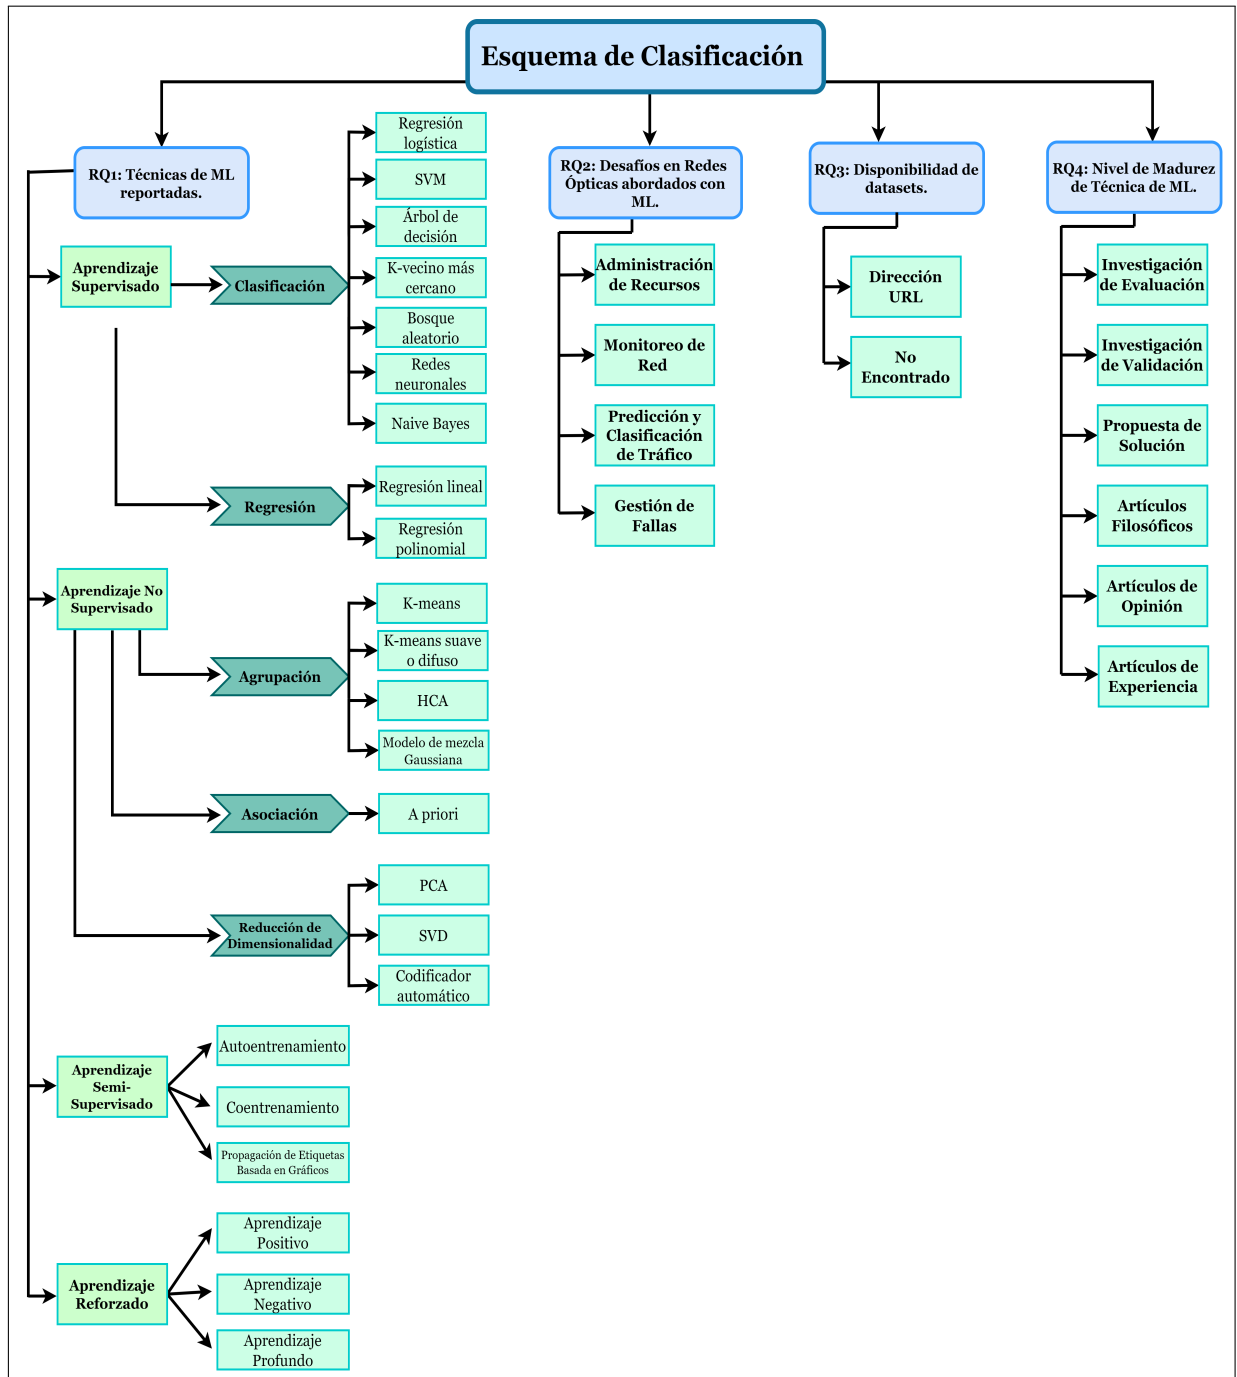


Figura 2.3: Esquema de clasificación.

La Figura 2.3 presenta la información a ser extraída durante la etapa de codificación de los artículos seleccionados. Se han creado 4 dimensiones principales (recuadros celestes), que son las preguntas de investigación planteadas en la etapa de planificación. A su vez, cada

dimensión cuenta con un cierto número de atributos (recuadros verdes), que son aquellos datos que necesitan ser extraídos de cada una de las contribuciones. De un mismo artículo, se pueden extraer uno o varios atributos para una determinada dimensión. Los atributos que permiten responder a RQ1 y RQ2 se han descrito en el Capítulo I (técnicas de ML y áreas de trabajo en redes ópticas en las que se podría aplicar ML). Para RQ3, se designa como atributo la posibilidad de encontrar la dirección URL o no de los datasets utilizados en el artículo y finalmente para RQ4, sus atributos se obtuvieron a partir de la Tabla 2.4, que permite diferenciar las técnicas de ML probadas empíricamente (investigaciones de evaluación y validación), de aquellas que no están probadas empíricamente (propuestas de solución, artículos filosóficos, de opinión o experiencias). Con el objetivo de poder describir la madurez de los estudios analizados, en función de los esfuerzos que realizaron sus autores para validarlos [56]. En concreto, los atributos de esta dimensión corresponden a los tipos de investigación planteados en [65].

Tabla 2.4: Atributos de la dimensión Nivel de Madurez [65].

Tipo de Investigación	Descripción
Investigación de Evaluación	"Las técnicas se implementan en la práctica y se realiza una evaluación de la técnica. Es decir, se muestra cómo se implementa la técnica en la práctica (implementación de la solución) y cuáles son las consecuencias de la implementación en términos de beneficios y desventajas (evaluación de la implementación). Esto también incluye identificar problemas en la industria".
Investigación de Validación	"Las técnicas investigadas son novedosas o una actualización significativa y aún no se han implementado en la práctica. Las técnicas utilizadas son, por ejemplo, experimentos, es decir, trabajos realizados en el laboratorio".
Propuesta de Solución	"Se propone una solución para un problema, la solución puede ser novedosa o una extensión significativa de una técnica existente. Los beneficios potenciales y la aplicabilidad de la solución se muestran con un pequeño ejemplo o una buena línea de argumentación".
Artículos Filosóficos	"Estos artículos esbozan una nueva forma de ver las cosas existentes al estructurar el campo en forma de taxonomía o marco conceptual".
Artículos de Opinión	"Estos trabajos expresan la opinión de alguien sobre si una determinada técnica es buena o mala, o cómo se deben hacer las cosas. No se basan en metodologías de trabajo e investigación relacionadas".
Artículos de Experiencia	"Los documentos de experiencia explican qué y cómo se ha hecho algo en la práctica. Tiene que ser la experiencia personal del autor".

2.2 REALIZACIÓN (CONDUCTING)

La etapa de realización, permite cumplir con el segundo y tercer objetivo específico descritos en este componente. Es decir, ejecutar la revisión sistemática de la literatura existente acerca del uso de técnicas de ML para resolver problemas relacionados con el funcionamiento y operación de redes ópticas. Así como, clasificar la información obtenida de acuerdo con los problemas relacionados con redes ópticas y técnicas empleadas para su solución.

La realización (conducting) es el camino que ayuda a responder a las preguntas de investigación planteadas en la etapa de planificación. Con este propósito en mente, se lleva a cabo la exploración de artículos en Scopus haciendo uso de la cadena de búsqueda definida anteriormente. Se filtran los resultados según los criterios de inclusión-exclusión automáticos y manuales planteados previamente y se codifican los artículos restantes utilizando el esquema de clasificación diseñado. Hasta el 26 de julio de 2022, se obtuvo como resultado 841 artículos con la cadena de búsqueda original que se había definido y luego de aplicar los diferentes filtros automáticos y manuales, se trabaja finalmente con el análisis de 96 artículos en el presente proyecto. La Figura 2.4 muestra el número de documentos que fueron considerados en cada proceso de la sección de planificación.

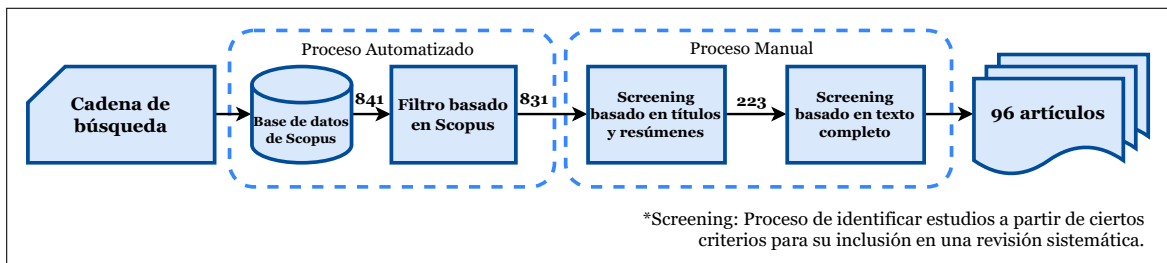


Figura 2.4: Alcance del estudio, basado en [56].

La lista de los 96 trabajos seleccionados se visualiza en la Tabla 2.5. A cada contribución, se le ha asignado un determinado ID. Con el cual, se identificará y se citará a los artículos, en la descripción de análisis de resultados en el Capítulo 3 de este proyecto.

Tabla 2.5: Lista de publicaciones examinadas.

ID del artículo	Referencias
ID7	IEE Alsarhan, A., Agarwal, A. (2009). Spectrum sharing in multi-service cognitive network using reinforcement learning. Proceedings - 2009 1st UK-India International Workshop on Cognitive Wireless Systems, UKIWCWS 2009. https://doi.org/10.1109/UKIWCWS.2009.5749427 .
ID16	Proactive restoration of optical links based on the classification of events IEEE Conference Publication IEEE Xplore. (n.d.). Retrieved January 5, 2023, from https://ieeexplore.ieee.org/document/5753394 .
ID29	Obaidat, M. S., Holzinger, A., Filipe, J. (Eds.). (2015). E-Business and Telecommunications (Vol. 554). https://doi.org/10.1007/978-3-319-25915-4
ID36	Informationstechnische Gesellschaft im VDE, Verband der Elektrotechnik, E., Institute of Electrical and Electronics Engineers. (n.d.). ECOC 2016; 42nd European Conference on Optical Communication: 18-22 Sept. 2016.
ID43	Viljoen, N., Rastegarfar, H., Yang, M., Wissinger, J., Glick, M. (2016). Machine learning based adaptive flow classification for optically interconnected data centers. International Conference on Transparent Optical Networks, 2016-August. https://doi.org/10.1109/ICTON.2016.7550294 .

Tabla 2.5 – continuación de la página anterior.

ID del artículo	Referencias
ID59	Thrane, J., Wass, J., Piels, M., Diniz, J. C. M., Jones, R., Zibar, D. (2017). Machine Learning Techniques for Optical Performance Monitoring from Directly Detected PDM-QAM Signals. <i>Journal of Lightwave Technology</i> , 35(4), 868–875. https://doi.org/10.1109/JLT.2016.2590989 .
ID66	Panayiotou, T., Chatzis, S. P., Ellinas, G. (2017). A probabilistic approach for failure localization. 2017 21st International Conference on Optical Network Design and Modeling, ONDM 2017 - Conference Proceedings. https://doi.org/10.23919/ONDM.2017.7958555
ID67	Gosselin, S., Courant, J. L., Tembo, S. R., Vaton, S. (2017). Application of probabilistic modeling and machine learning to the diagnosis of FTTH GPON networks. 2017 21st International Conference on Optical Network Design and Modeling, ONDM 2017 - Conference Proceedings. https://doi.org/10.23919/ONDM.2017.7958529 .
ID69	Wang, Z., Zhang, M., Wang, D., Song, C., Liu, M., Li, J., Lou, L., Liu, Z. (2017). Failure prediction using machine learning and time series in optical network. <i>Optics Express</i> , 25(16), 18553. https://doi.org/10.1364/oe.25.018553 .
ID72	Morales, F., Ruiz, M., Velasco, L. (2017). Data analytics-based origin-destination core traffic modelling. International Conference on Transparent Optical Networks. https://doi.org/10.1109/ICTON.2017.8024980 .
ID79	Samadi, P., Amar, D., Lepers, C., Lourdiane, M., Bergman, K. (2017). Quality of Transmission Prediction with Machine Learning for Dynamic Operation of Optical WDM Networks. European Conference on Optical Communication, ECOC, 2017-September, 1–3. https://doi.org/10.1109/ECOC.2017.8346216 .
ID92	Lu, H., Cui, S., Ke, C., Liu, D. (2017). Automatic reference optical spectrum retrieval method for ultra-high resolution optical spectrum distortion analysis utilizing integrated machine learning techniques References and links. http://aragonphotonics.com/bosa-100-400 .
ID102	Machine-Learning-Based Soft-Failure Detection and Identification in Optical Networks IEEE Conference Publication IEEE Xplore. (n.d.). Retrieved January 5, 2023, from https://ieeexplore.ieee.org/document/8385774
ID106	Seve, E., Pesic, J., Delezoide, C., Bigo, S., Pointurier, Y. (2018). Learning process for reducing uncertainties on network parameters and design margins. <i>Journal of Optical Communications and Networking</i> , 10(2), A298–A306. https://doi.org/10.1364/JOCN.10.00A298 .
ID107	Rottondi, C., Barletta, L., Giusti, A., Tornatore, M. (2018). Machine-learning method for quality of transmission prediction of unestablished lightpaths. <i>Journal of Optical Communications and Networking</i> , 10(2), A286–A297. https://doi.org/10.1364/JOCN.10.00A286 .
ID109	Panayiotou, T., Chatzis, S. P., Ellinas, G. (2018). Leveraging statistical machine learning to address failure localization in optical networks. <i>Journal of Optical Communications and Networking</i> , 10(3), 162–173. https://doi.org/10.1364/JOCN.10.000162 .
ID111	Wang, L., Wang, X., Tornatore, M., Kim, K. J., Kim, S. M., Kim, D. U., Han, K. E., Mukherjee, B. (2018). Scheduling with machine-learning-based flow detection for packet-switched optical data center networks. <i>Journal of Optical Communications and Networking</i> , 10(4), 365–375. https://doi.org/10.1364/JOCN.10.000365 .
ID114	Rafique, D., Szyrkowiec, T., Grießer, H., Autenrieth, A., Elbers, J. P. (2018). Cognitive Assurance Architecture for Optical Network Fault Management. <i>Journal of Lightwave Technology</i> , 36(7), 1443–1450. https://doi.org/10.1109/JLT.2017.2781540 .
ID125	S. Shahkarami, F. Musumeci, F. Cugini, and M. Tornatore, “Machine-Learning-Based Soft-Failure Detection and Identification in Optical Networks,” <i>Optical Fiber Communication Conference (2018)</i> , paper M3A.5, vol. Part F84-OFC 2018, p. M3A.5, Mar. 2018, doi: 10.1364/OFC.2018.M3A.5.

Tabla 2.5 – continuación de la página anterior.

ID del artículo	Referencias
ID128	B. Shariati, A. P. Vela, M. Ruiz, and L. Velasco, "Monitoring and data analytics: Analyzing the optical spectrum for soft-failure detection and identification," 22nd Conference on Optical Network Design and Modelling, ONDM 2018 - Proceedings, pp. 260–265, Jun. 2018, doi: 10.23919/ONDM.2018.8396142.
ID129	Frigui, N. E., Lemlouma, T., Gosselin, S., Radier, B., le Meur, R., Bonnin, J. M. (2018). Optimization of the upstream bandwidth allocation in passive optical networks using internet users' behavior forecast. 22nd Conference on Optical Network Design and Modelling, ONDM 2018 - Proceedings, 59–64. https://doi.org/10.23919/ONDM.2018.8396107 .
ID136	Ruan, L., Mondal, S., Wong, E. (2018). Machine learning based bandwidth prediction in tactile heterogeneous access networks. INFOCOM 2018 - IEEE Conference on Computer Communications Workshops, 1–2. https://doi.org/10.1109/INFCOMW.2018.8406834 .
ID139	Chen, X., Proietti, R., Lu, H., Castro, A., Yoo, S. J. B. (2018). Knowledge-based autonomous service provisioning in multi-domain elastic optical networks. IEEE Communications Magazine, 56(8), 152–158. https://doi.org/10.1109/MCOM.2018.1701191 .
ID143	Panayiotou, T., Ellinas, G. (2018). Data-Driven Bandwidth Allocation in EONs. Proceedings of the 2018 Photonics in Switching and Computing, PSC 2018. https://doi.org/10.1109/PS.2018.8751369 .
ID151	Troia, S., Alvizu, R., Zhou, Y., Maier, G., Pattavina, A. (2018). Deep Learning-Based Traffic Prediction for Network Optimization. International Conference on Transparent Optical Networks, 2018-July. https://doi.org/10.1109/ICTON.2018.8473978 .
ID156	Vela, A. P., Ruiz, M., Velasco, L. (2018). Examples of Machine Learning Algorithms for Optical Network Control and Management. International Conference on Transparent Optical Networks, 2018-July. https://doi.org/10.1109/ICTON.2018.8473900 .
ID158	Morais, R. M., Pedro, J. (2018). Evaluating Machine Learning Models for QoT Estimation. International Conference on Transparent Optical Networks, 2018-July. https://doi.org/10.1109/ICTON.2018.8473941 .
ID163	Mata, J., Miguel, I. de, Duran, R. J., Aguado, J. C., Merayo, N., Ruiz, L., Fernandez, P., Lorenzo, R. M., Abril, E. J., Tomkos, I. (2018). Supervised Machine Learning Techniques for Quality of Transmission Assessment in Optical Networks. International Conference on Transparent Optical Networks, 2018-July. https://doi.org/10.1109/ICTON.2018.8473819 .
ID166	Morais, R. M., Pedro, J. (2018). Machine learning models for estimating quality of transmission in DWDM networks. Journal of Optical Communications and Networking, 10(10), D84–D99. https://doi.org/10.1364/JOCN.10.000D84 .
ID172	Zhao, Y., Yan, B., Liu, D., He, Y., Wang, D., Zhang, J. (2018). SOON: self-optimizing optical networks with machine learning. Optics Express, 26(22), 28713. https://doi.org/10.1364/oe.26.028713 .
ID174	Aibin, M. (2018). Traffic prediction based on machine learning for elastic optical networks. Optical Switching and Networking, 30, 33–39. https://doi.org/10.1016/j.osn.2018.06.001 .
ID189	Sartzetakis, I., Christodouloupoulos, K., Varvarigos, E. (n.d.). Formulating QoT Estimation with Machine Learning. http://www.ciena.com/products/wavelogic/wavelogic-Ai/ .
ID200	Allogba, S., Tremblay, C. (2018). K-Nearest Neighbors Classifier for Field Bit Error Rate Data. Asia Communications and Photonics Conference, ACP, 2018-October. https://doi.org/10.1109/ACP.2018.8596133 .
ID207	Lippiatt, D., Varughese, S., Richter, T., Tibuleac, S., Ralph, S. E. (2019). Machine-learning-based optical performance monitoring using carrier phase recovery. IET Conference Publications, 2019(CP765). https://doi.org/10.1049/CP.2019.0955 .
ID209	Tremblay, C., Allogba, S., Aladin, S. (2019). Quality of transmission estimation and performance prediction of lightpaths using machine learning. IET Conference Publications, 2019(CP765). https://doi.org/10.1049/CP.2019.0757 .

Tabla 2.5 – continuación de la página anterior.

ID del artículo	Referencias
ID221	Panayiotou, T., Savva, G., Behnam, S., Tomkos, I., & Ellinas, G. (2019). Machine Learning for QoT Estimation of Unseen Optical Network States; Machine Learning for QoT Estimation of Unseen Optical Network States. In <i>2019 Optical Fiber Communications Conference and Exhibition (OFC)</i> .
ID228	Rahouma, K. H., & Ali, A. (2019). Applying Machine Learning Technology to Optimize the Operational Cost of the Egyptian Optical Network. <i>Procedia Computer Science</i> , 163, 502–517. https://doi.org/10.1016/j.procs.2019.12.133 .
ID242	Hatem, J. A., Dhaini, A. R., & Elbassuoni, S. (2019). Deep learning-based dynamic bandwidth allocation for future optical access networks. <i>IEEE Access</i> , 7, 97307–97318. https://doi.org/10.1109/ACCESS.2019.2929480 .
ID255	Tanimura, T., Hoshida, T., Kato, T., Watanabe, S., & Morikawa, H. (2019). Convolutional neural network-based optical performance monitoring for optical transport networks. <i>Journal of Optical Communications and Networking</i> , 11(1), A52–A59. https://doi.org/10.1364/JOCN.11.000A52 .
ID256	Proietti, R., Chen, X., Zhang, K., Liu, G., Shamsabardeh, M., Castro, A., Velasco, L., Zhu, Z., ben Yoo, S. J. (2019). Experimental Demonstration of Machine-Learning-Aided QoT Estimation in Multi-Domain Elastic Optical Networks with Alien Wavelengths. <i>Journal of Optical Communications and Networking</i> , Vol. 11, Issue 1, Pp. A1-A10, 11(1), A1–A10. https://doi.org/10.1364/JOCN.11.0000A1 .
ID262	Yan, B., Zhao, Y., Li, Y., Yu, X., Zhang, J., Wang, Y., Yan, L., Rahman, S. (2019). Actor-Critic-Based Resource Allocation for Multi-Modal Optical Networks. 2018 IEEE Globecom Workshops, GC Wkshps 2018 - Proceedings. https://doi.org/10.1109/GLOCOMW.2018.8644190
ID267	Salani, M., Rottondi, C., Tornatore, M. (2019). Routing and Spectrum Assignment Integrating Machine-Learning-Based QoT Estimation in Elastic Optical Networks. Proceedings - IEEE INFOCOM, 2019-April, 1738–1746. https://doi.org/10.1109/INFOCOM.2019.8737413 .
ID275	Liu, B., Zhang, L., Wang, F., Liu, M., Mao, Y., Zhao, L., Sun, T., Xin, X. (2019). Adaptive dynamic wavelength and bandwidth allocation algorithm based on error-back-propagation neural network prediction. <i>Optics Communications</i> , 437, 276–284. https://doi.org/10.1016/j.optcom.2018.12.064 .
ID281	Panayiotou, T., Savva, G., Behnam, S., Tomkos, I., Ellinas, G. (n.d.). Machine Learning for QoT Estimation of Unseen Optical Network States.
ID283	Ruan, L., Dias, I., Wong, E. (2019). Machine intelligence in supervising bandwidth allocation for low-latency communications. <i>IEEE International Conference on High Performance Switching and Routing, HPSR</i> , 2019-May. https://doi.org/10.1109/HPSR.2019.8808127 .
ID291	Panayiotou, T., Manousakis, K., Chatzis, S. P., Ellinas, G. (2019). A Data-Driven Bandwidth Allocation Framework With QoS Considerations for EONs. <i>Journal of Lightwave Technology</i> , Vol. 37, Issue 9, Pp. 1853-1864, 37(9), 1853–1864. https://opg.optica.org/abstract.cfm?uri=jlt-37-9-1853 .
ID306	Szostak, D., Walkowiak, K. (2019). Machine learning methods for traffic prediction in dynamic optical networks with service chains. <i>International Conference on Transparent Optical Networks</i> , 2019-July. https://doi.org/10.1109/ICTON.2019.8840301 .
ID318	Zhang, M., Wang, D. (2019). Machine Learning Based Alarm Analysis and Failure Forecast in Optical Networks. <i>OECG/PSC 2019 - 24th OptoElectronics and Communications Conference/International Conference Photonics in Switching and Computing 2019</i> . https://doi.org/10.23919/PS.2019.8817991 .
ID331	Musumeci, F., Rottondi, C., Corani, G., Shahkarami, S., Cugini, F., Tornatore, M. (2019). A Tutorial on Machine Learning for Failure Management in Optical Networks. <i>Journal of Lightwave Technology</i> , 37(16), 4125–4139. https://doi.org/10.1109/JLT.2019.2922586 .

Tabla 2.5 – continuación de la página anterior.

ID del artículo	Referencias
ID339	Martín, I., Troia, S., Hernández, J. A., Rodríguez, A., Musumeci, F., Maier, G., Alvizu, R., de Dios, Ó. G. (2019). Machine learning-based routing and wavelength assignment in software-defined optical networks. <i>IEEE Transactions on Network and Service Management</i> , 16(3). https://doi.org/10.1109/TNSM.2019.2927867 .
ID352	Butt, R. A., Faheem, M., Arfeen, A., Ashraf, M. W., Jawed, M. (2019). Machine learning based dynamic load balancing DWBA scheme for TWDM PON. <i>Optical Fiber Technology</i> , 52. https://doi.org/10.1016/j.yofte.2019.101964 .
ID361	Panayiotou, T., Savvas, G., Tomkos, I., Ellinas, G. (2019). Centralized and distributed machine learning-based QoT estimation for sliceable optical networks. 2019 IEEE Global Communications Conference, GLOBECOM 2019 - Proceedings. https://doi.org/10.1109/GLOBECOM38437.2019.9013962 .
ID396	Guo, H., Wang, C., Tang, Y., Zhu, Y., Wu, J., Zuo, Y. (2020). Machine Learning Assisted Optical Network Resource Scheduling in Data Center Networks. <i>Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)</i> , 11616 LNCS, 204–210. https://doi.org/10.1007/978-3-030-38085-4_18/COVER .
ID420	Xing, X., Zhao, Y., Li, Y., Zhang, J. (2020, March 1). Knowledge-Based Collective Self-learning for Alarm Prediction in Real Multi-Domain Autonomous Optical Networks. 2020 16th International Conference on the Design of Reliable Communication Networks, DRCN 2020. https://doi.org/10.1109/DRCN48652.2020.1570611066 .
ID452	Shu, L., Yu, Z., Wan, Z., Zhang, J., Hu, S., Xu, K. (2020). Dual-Stage Soft Failure Detection and Identification for Low-Margin Elastic Optical Network by Exploiting Digital Spectrum Information. <i>Journal of Lightwave Technology</i> , 38(9), 2669–2679. https://doi.org/10.1109/JLT.2019.2947562 .
ID455	Ruan, L., Dias, M. P. I., Wong, E. (2020). Towards self-adaptive bandwidth allocation for low-latency communications with reinforcement learning. <i>Optical Switching and Networking</i> , 37. https://doi.org/10.1016/j.osn.2020.100567 .
ID457	Aladin, S., Tran, A. V. S., Allogba, S., Tremblay, C. (2020). Quality of Transmission Estimation and Short-Term Performance Forecast of Lightpaths. <i>Journal of Lightwave Technology</i> , 38(10), 2806–2813. https://doi.org/10.1109/JLT.2020.2975179 .
ID461	Lun, H., Fu, M., Liu, X., Wu, Y., Yi, L., Hu, W., Zhuge, Q. (2020). Soft Failure Identification for Long-haul Optical Communication Systems Based on One-dimensional Convolutional Neural Network. <i>Journal of Lightwave Technology</i> , 38(11), 2992–2999. https://doi.org/10.1109/JLT.2020.2989153 .
ID464	Wang, Y., Cheng, B., Hang, C., Yu, J., Liu, S., Hu, Y., Shen, J. (2020). Routing Algorithm for Elastic Optical Network Based on Machine Learning assisted Traffic Prediction. <i>Journal of Physics: Conference Series</i> , 1550(3). https://doi.org/10.1088/1742-6596/1550/3/032123 .
ID470	Mitropoulou, K., Sartzetakis, I., Varvarigos, E. (2020). Soft failure detection, categorization and localization. <i>International Conference on Transparent Optical Networks</i> , 2020-July. https://doi.org/10.1109/ICTON51198.2020.9203373 .
ID471	Szostak, D., Walkowiak, K., Włodarczyk, A. (2020). Short-term traffic forecasting in optical network using linear discriminant analysis machine learning classifier. <i>International Conference on Transparent Optical Networks</i> , 2020-July. https://doi.org/10.1109/ICTON51198.2020.9203040 .
ID473	Khan, I., Bilal, M., Curri, V. (2020). Advanced formulation of QoT-Estimation for un-established lightpaths using cross-train machine learning methods. <i>International Conference on Transparent Optical Networks</i> , 2020-July. https://doi.org/10.1109/ICTON51198.2020.9203334 .
ID478	Khan, I., Bilal, M., Siddiqui, M., Khan, M., Ahmad, A., Shahzad, M., Curri, V. (2020). QoT estimation for light-path provisioning in un-seen optical networks using machine learning. <i>International Conference on Transparent Optical Networks</i> , 2020-July. https://doi.org/10.1109/ICTON51198.2020.9203364 .

Tabla 2.5 – continuación de la página anterior.

ID del artículo	Referencias
ID491	Pandya, R. J. (2020). Machine learning-oriented resource allocation in C + L + S bands extended SDM-EONs. <i>IET Communications</i> , 14(12), 1957–1967. https://doi.org/10.1049/iet-com.2019.1191 .
ID498	Szostak, D., Walkowiak, K. (2020). Application of Machine Learning Algorithms for Traffic Forecasting in Dynamic Optical Networks with Service Function Chains. <i>Foundations of Computing and Decision Sciences</i> , 45(3), 217–232. https://doi.org/10.2478/fcds-2020-0012 .
ID519	Khan, I., Bilal, M., Curri, V. (2020). Assessment of cross-train machine learning techniques for QoT-estimation in agnostic optical networks. <i>OSA Continuum</i> , 3(10), 2690. https://doi.org/10.1364/osac.399511 .
ID529	Zhi, C., Ji, W., Yin, R., Feng, J., Xu, H., Li, Z., Wang, Y. (2020). The flexible resource management in optical data center networks based on machine learning and SDON. <i>Optical Switching and Networking</i> , 39. https://doi.org/10.1016/j.osn.2020.100594 .
ID533	Valkanis, A., Beletsioti, G. A., Nicopolitidis, P., Papadimitriou, G., Varvarigos, E. (2020, November 3). Reinforcement Learning in Traffic Prediction of Core Optical Networks using Learning Automata. <i>Proceedings of the 2020 IEEE International Conference on Communications, Computing, Cybersecurity, and Informatics, CCCI 2020</i> . https://doi.org/10.1109/CCCI49893.2020.9256655 .
ID558	Andreoletti, D., Rottondi, C. E., Margherita, ;, Bianco, A., Giordano, Silvia.-E. (2021). A Machine Learning Framework for Scalable Routing and Wavelength Assignment in Large Optical Networks <i>IEEE Conference Publication IEEE Xplore</i> . (n.d.). Retrieved January 5, 2023, from https://ieeexplore.ieee.org/document/9489780
ID574	Sun, K., Yu, Z., Shu, L., Wan, Z., Huang, H., Xu, K. (2021). Experimental Demonstration of Soft Failure Identification Based on Digital Residual Spectrum and Machine Learning. <i>2021 6th International Conference on UK-China Emerging Technologies, UCET 2021</i> , 81–84. https://doi.org/10.1109/UCET54125.2021.9674951 .
ID581	Yao, C. C., Zheng, J. Y., Jou, J. J., Yang, C. L. (2021). Performance Monitoring of High-Speed NRZ Signals Using Machine Learning Techniques. <i>ISPACS 2021 - International Symposium on Intelligent Signal Processing and Communication Systems: 5G Dream to Reality, Proceeding</i> . https://doi.org/10.1109/ISPACS51563.2021.9650979 .
ID595	Gupta, G., Rai, A., Jha, V. (2021). Predicting the Bandwidth Requests in XG-PON System using Ensemble Learning. <i>International Conference on ICT Convergence, 2021-October</i> , 936–941. https://doi.org/10.1109/ICTC52510.2021.9620935 .
ID608	Cichosz, P., Kozdrowski, S., Sujecki, S. (2021). Application of ML algorithms for prediction of the QoT in optical networks with imbalanced and incomplete data. <i>2021 29th International Conference on Software, Telecommunications and Computer Networks, SoftCOM 2021</i> . https://doi.org/10.23919/SOFTCOM52868.2021.9559095 .
ID638	Kozdrowski, S., Cichosz, P., Paziewski, P., Sujecki, S. (2021). Machine learning algorithms for prediction of the quality of transmission in optical networks. <i>Entropy</i> , 23(1), 1–18. https://doi.org/10.3390/e23010007 .
ID648	Das, D., Imteyaz, M. F., Bapat, J., Das, D. (2021). A Non-intrusive Failure Prediction Mechanism for Deployed Optical Networks. <i>2021 International Conference on COMMunication Systems and NETWORKS, COMSNETS 2021</i> , 24–28. https://doi.org/10.1109/COMSNETS51098.2021.9352868 .
ID650	Saif, W. S., Ragheb, A. M., Alshawi, T. A., Alshebeili, S. A. (2021). Optical Performance Monitoring in Mode Division Multiplexed Optical Networks. <i>Journal of Lightwave Technology</i> , 39(2), 491–504. https://doi.org/10.1109/JLT.2020.3027725 .
ID670	Ibrahimi, M., Abdollahi, H., Rottondi, C., Giusti, A., Ferrari, A., Curri, V., Tornatore, M. (2021). Machine learning regression for QoT estimation of unestablished lightpaths. <i>Journal of Optical Communications and Networking</i> , 13(4), B92–B101. https://doi.org/10.1364/JOCN.410694 .

Tabla 2.5 – continuación de la página anterior.

ID del artículo	Referencias
ID677	Das, D., Imteyaz, M. F., Bapat, J., Das, D. (2021). A Data Augmented Bayesian Network for Node Failure Prediction in Optical Networks. 3rd International Conference on Artificial Intelligence in Information and Communication, ICAIIC 2021, 83–88. https://doi.org/10.1109/ICAIIIC51459.2021.9415186 .
ID695	Esmail, M. A. (2021). Optical Wireless Performance Monitoring Using Asynchronous Amplitude Histograms. <i>IEEE Photonics Journal</i> , 13(3). https://doi.org/10.1109/JPHOT.2021.3080593 .
ID697	Paudyal, P., Shen, S., Yan, S., Simeonidou, D. (2021). Toward Deployments of ML Applications in Optical Networks. <i>IEEE Photonics Technology Letters</i> , 33(11), 537–540. https://doi.org/10.1109/LPT.2021.3074586 .
ID702	Aibin, M., Chung, N., Gordon, T., Lyford, L., Vinchoff, C. (2021, June 28). On Short- and Long-Term Traffic Prediction in Optical Networks Using Machine Learning. 25th International Conference on Optical Network Design and Modelling, ONDM 2021. https://doi.org/10.23919/ONDM51796.2021.9492437 .
ID706	Szostak, D., Włodarczyk, A., & Walkowiak, K. (2021). Machine learning classification and regression approaches for optical network traffic prediction. <i>Electronics (Switzerland)</i> , 10(13). https://doi.org/10.3390/electronics10131578 .
ID716	Zhang, C., Wang, D., Wang, L., Guan, L., Yang, H., Zhang, Z., Chen, X., & Zhang, M. (2021). Cause-aware failure detection using an interpretable XGBoost for optical networks. <i>Optics Express</i> , 29(20), 31974. https://doi.org/10.1364/oe.436293 .
ID720	Usmani, F., Khan, I., Masood, M. U., Ahmad, A., Shahzad, M., & Curri, V. (2021). Convolutional neural network for quality of transmission prediction of unestablished lightpaths. <i>Microwave and Optical Technology Letters</i> , 63(10), 2461–2469. https://doi.org/10.1002/mop.32996 .
ID726	Lu, J., Fan, Q., Zhou, G., Lu, L., Yu, C., Lau, A. P. T., & Lu, C. (2021). Automated training dataset collection system design for machine learning application in optical networks: An example of quality of transmission estimation. <i>Journal of Optical Communications and Networking</i> , 13(11), 289–300. https://doi.org/10.1364/JOCN.431780 .
ID733	Usmani, F., Khan, I., Siddiqui, M., Khan, M., Bilal, M., Masood, M. U., Ahmad, A., Shahzad, M., & Curri, V. (2021). Cross-feature trained machine learning models for QoT-estimation in optical networks. https://doi.org/10.1117/1.OE.60.12.125106 , 60(12), 125106. https://doi.org/10.1117/1.OE.60.12.125106 .
ID736	Lonardi, M., Pesic, J., Zami, T., Seve, E., & Rossi, N. (2021). Machine learning for quality of transmission: A picture of the benefits fairness when planning WDM networks. <i>Journal of Optical Communications and Networking</i> , 13(12), 331–346. https://doi.org/10.1364/JOCN.433412 .
ID740	Fu, Y., Chen, J., Wu, W., Huang, Y., Hong, J., Chen, L., & Li, Z. (2021). A QoT prediction technique based on machine learning and NLSE for QoS and new lightpaths in optical communication networks. <i>Frontiers of Optoelectronics</i> , 14(4), 513–521. https://doi.org/10.1007/s12200-020-1079-y .
ID765	Ayoub, O., Bianco, A., Andreoletti, D., Troia, S., Giordano, S., & Rottondi, C. (2022). On the Application of Explainable Artificial Intelligence to Lightpath QoT Estimation; / <i>IEEE Conference Publication IEEE Xplore</i> . (n.d.). Retrieved January 5, 2023, from https://ieeexplore.ieee.org/document/9748572 .
ID778	Silva, M. F., Pacini, A., Sgambelluri, A., & Valcarenghi, L. (2022). Learning Long- and Short-Term Temporal Patterns for ML-Driven Fault Management in Optical Communication Networks. <i>IEEE Transactions on Network and Service Management</i> , 19(3), 2195–2206. https://doi.org/10.1109/TNSM.2022.3146869 .
ID786	Menaghapriya, B. R., & Sangeetha, R. G. (2022). Failure Detection Using Artificial Neural Networks. <i>Lecture Notes in Electrical Engineering</i> , 792, 655–661. https://doi.org/10.1007/978-981-16-4625-6_65 .

Tabla 2.5 – continuación de la página anterior.

ID del artículo	Referencias
ID787	Khan, I., Bilal, M., & Curri, V. (2022). Cross-Train: Machine Learning Assisted QoT-Estimation in Un-used Optical Networks. <i>Lecture Notes in Electrical Engineering</i> , 797 LNEE, 78–87. https://doi.org/10.1007/978-981-16-5692-7_9/COVER .
ID814	Allogba, S., Aladin, S., & Tremblay, C. (2022). Machine-Learning-Based Lightpath QoT Estimation and Forecasting. <i>Journal of Lightwave Technology</i> , 40(10), 3115–3127. https://doi.org/10.1109/JLT.2022.3160379 .
ID816	Usman, A., Zulkifli, N., Salim, M. R., & Khairi, K. (2022). Fault monitoring in passive optical network through the integration of machine learning and fiber sensors. <i>International Journal of Communication Systems</i> , 35(9). https://doi.org/10.1002/dac.5134 .
ID820	Guo, N., Li, L., Mukherjee, B., & Shen, G. (2022). Protection against failure of machine-learning-based QoT prediction. <i>Journal of Optical Communications and Networking</i> , Vol. 14, Issue 7, Pp. 572-585, 14(7), 572–585. https://doi.org/10.1364/JOCN.457313 .
ID827	Cheng, L., & Qiu, Y. (2022). Routing and spectrum assignment employing long short-term memory technique for elastic optical networks. <i>Optical Switching and Networking</i> , 45. https://doi.org/10.1016/j.osn.2022.100684 .

La Figura 2.5 presenta un ejemplo de archivo de codificación realizado en CADIMA. De las 96 contribuciones, se extraen todos los atributos que permitan clasificar las técnicas de ML empleadas para resolver algún problema relacionados con el funcionamiento y operación de redes ópticas, la disponibilidad del dataset del estudio y se asigna un determinado nivel de madurez a la investigación.

Figura 2.5: Área de extracción de datos en CADIMA.

Luego de la finalización del proceso de extracción de datos, CADIMA almacena la información recolectada en la plataforma. Para ser visualizada, es necesario descargarla de su página web. El archivo resultante, es una base de datos en el formato de una hoja de cálculo de Excel, la cual puede ser observada en el repositorio del ANEXO I.

Al mismo tiempo que se realiza la codificación de datos en CADIMA, se hace uso de una herramienta adicional, NVIVO (<https://nvivo-spain.com/>). Programa que se emplea para el análisis y extracción de información. Este software de paga, integra las principales herramientas para trabajos con documentos textuales, multimediales, datos de encuesta y datos bibliográficos, con el objetivo de volver más efectivo el trabajo desarrollado por investigadores. Pues permite administrar y analizar información en diferentes formatos [66]. NVIVO fue una herramienta de gran apoyo que permitió ordenar, relacionar y resumir datos adicionales obtenidos a partir del análisis de los 96 artículos.

2.3 PRESENTACIÓN (REPORTING)

La etapa de presentación permite cumplir con el tercer y cuarto objetivo específico. Es decir, clasificar la información obtenida de acuerdo con los problemas relacionados con el funcionamiento y operación de redes ópticas y las técnicas de ML empleadas para su solución. Así como, determinar el nivel de madurez de las técnicas en función de los esfuerzos que realizaron sus autores para validar el estudio.

En esta sección se dan a conocer las respuestas a las cuatro preguntas de investigación planteadas anteriormente: (1) técnicas de ML empleadas para resolver problemas relacionados con el funcionamiento y operación de redes ópticas, (2) problemas relacionados con el funcionamiento y operación de redes ópticas que mayoritariamente se abordan con técnicas de ML, (3) la disponibilidad de los datasets empleados en las investigaciones y (4) el nivel de madurez de las técnicas desarrolladas en los estudios. Toda esta información es presentada en tablas y en forma gráfica para que pueda ser entendida de manera clara y sencilla, a la vez que se realiza su respectiva descripción de resultados. Adicionalmente, se discute acerca de los datos más relevantes que se han obtenido luego del proceso de codificación de los artículos objeto de estudio. Que tan prometedora es esta área de investigación, que temáticas son aquellas con mayor y menor interés de estudio y las brechas que aún se encuentran dentro de este campo de investigación, son algunos de los datos de mayor importancia que se han detectado durante este proyecto. Esta última etapa forma parte del Capítulo 3 del presente Trabajo de Integración Curricular.

3 RESULTADOS, CONCLUSIONES Y RECOMENDACIONES

3.1 RESULTADOS

Luego de realizar el proceso de codificación y análisis de los 96 artículos seleccionados, a continuación, se procede a responder las 4 preguntas de investigación planteadas en el Capítulo 2 de este proyecto.

3.1.1 RQ1—¿CUÁLES SON LAS TÉCNICAS DE ML UTILIZADAS PARA RESOLVER LOS PROBLEMAS REPORTADOS EN [2], [6], [7] RELACIONADOS CON EL FUNCIONAMIENTO Y OPERACIÓN DE REDES ÓPTICAS?

RQ1 busca proporcionar datos sobre qué técnicas de ML han sido empleadas en investigaciones anteriores para resolver los problemas reportados en [2], [6], [7], que se encuentran relacionados con el funcionamiento y operación de redes ópticas. Los resultados que permiten dar respuesta a esta pregunta, son discutidos a continuación.

Como se muestra en la Figura 3.1, la mayoría de las contribuciones analizadas, hacen uso de técnicas de aprendizaje supervisado (92 artículos) para resolver problemas relacionados con la administración de recursos, monitoreo de red, gestión de fallas y clasificación y predicción de tráfico de una red óptica (ver ID de artículos que abordan técnicas de ML supervisado vs. problema relacionado con el funcionamiento y operación de redes ópticas, en ANEXO II).

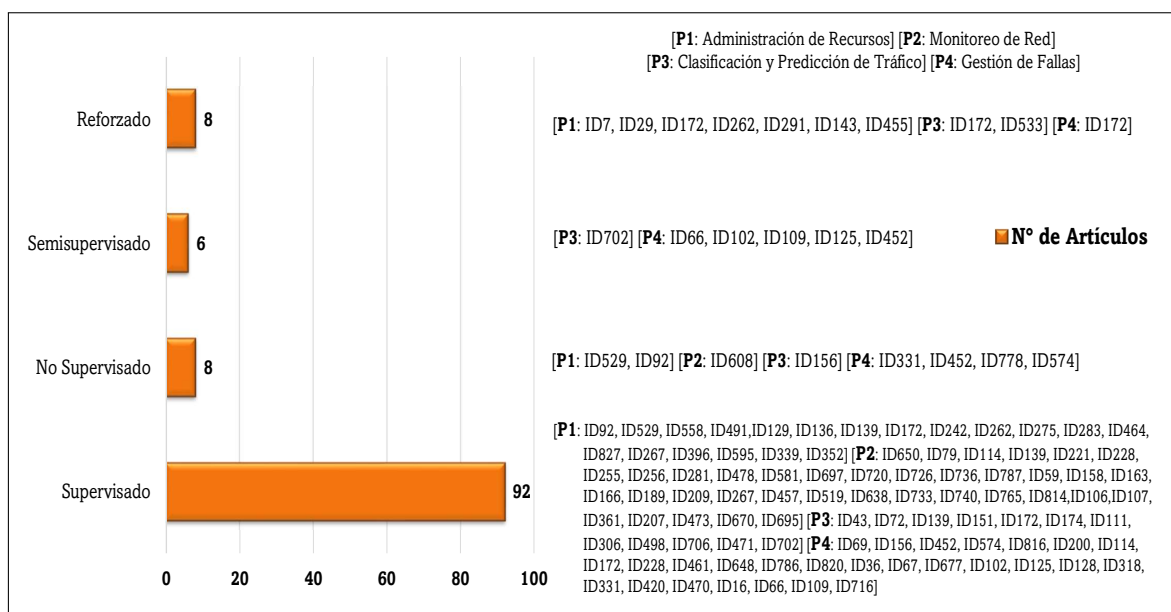


Figura 3.1: Técnica de ML reportadas para resolver problemas relacionados con el funcionamiento y operación de redes ópticas.

Estos resultados se obtienen debido a que estas técnicas supervisadas, al trabajar con

datos etiquetados donde los patrones de salida son conocidos por el sistema, hacen que estos algoritmos de aprendizaje logren resultados mucho más precisos, y con ello, solventar de mejor manera los problemas o desafíos alrededor de las redes ópticas (ID156). Por otra parte, existe un número reducido de contribuciones (6 artículos), que hacen uso de técnicas de aprendizaje semi-supervisado para abordar problemas como gestión de fallas y clasificación y predicción de tráfico (ver ID de artículos que abordan técnicas de ML semi-supervisado vs. problema relacionado con el funcionamiento y operación de redes ópticas, en ANEXO II). A consecuencia de que las respuestas que proporcionan las iteraciones al aplicar este tipo de técnicas son inestables y poco confiables, generando en muchas ocasiones, resultados no exitosos al tratar de resolver algún tipo de problema (ID102).

Cabe destacar que, aunque se ha trabajado con 96 artículos, más de uno de ellos, han empleado varias técnicas de ML dentro de una misma investigación. Por lo tanto, la sumatoria de número de artículos por cada técnica de ML empleada, sobrepasa el valor de contribuciones totales que han sido analizadas.

3.1.1.1 Técnicas de aprendizaje supervisado

De las 92 contribuciones que emplean técnicas de aprendizaje supervisado (Figura 3.2), el 90,22 % ($\frac{83 \cdot 100}{92}$) corresponden a algoritmos de clasificación y el 9,78 % hacen uso de algoritmos de regresión.

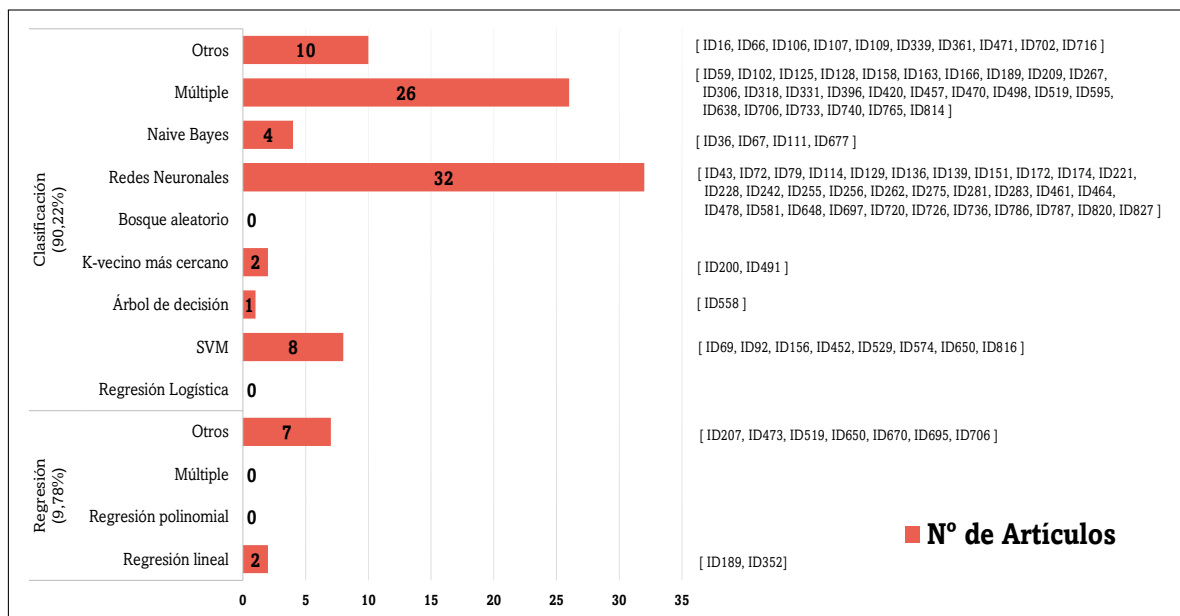


Figura 3.2: Contribuciones que han aportado a la resolución de problemas relacionados con el funcionamiento y operación de redes ópticas con técnicas de aprendizaje supervisado.

Dentro de los algoritmos de clasificación, las redes neuronales (34,78 %) son aquellas técnicas más utilizadas para resolver los problemas relacionados con la administración de

recursos, monitoreo de red, gestión de fallas y clasificación y predicción de tráfico de una red óptica (ver ID de artículos que abordan técnicas de ML supervisado vs. problema relacionado con el funcionamiento y operación de redes ópticas, en ANEXO II). Puesto que, al tratar de emular el modo en que el cerebro humano procesa la información, estos algoritmos presentan múltiples beneficios con su uso. Por ejemplo, una de las características más importantes, es que son capaces de organizar por sí mismas los datos aprendidos, reduciendo la complejidad del algoritmo para solventar un determinado problema (ID114). Además, presentan una clasificación variada que permite abarcar múltiples áreas de trabajo, desde las más sencillas hasta las más complejas (ID72). Durante el análisis de artículos, se identificó que ciertas investigaciones hacen uso de perceptrones multicapa (ID43), redes neuronales artificiales (ID72, ID114, ID129, ID172, ID174, ID228, ID256, ID262, ID275, ID283, ID478, ID581, ID697, ID726, ID736, ID787, ID820), redes neuronales convolucionales (ID172, ID221, ID255, ID281, ID720), redes neuronales recurrentes (ID151, ID242, ID464, ID827) y redes neuronales profundas (ID139, ID648, ID787). Adicionalmente, se identifica que alrededor de 26 contribuciones (28,26 %), hacen uso de una combinación de técnicas de aprendizaje supervisado (SVM, regresión logística, K- vecino más cercano, etc.), para solventar desafíos relacionados con la administración de recursos, monitoreo de red, gestión de fallas y clasificación y predicción de tráfico de una red óptica (ver ID de artículos que abordan técnicas de ML supervisado vs. problema relacionado con el funcionamiento y operación de redes ópticas, en ANEXO II), pues su objetivo es tratar de emplear las mejores características de cada algoritmo, para lograr predecir resultados mucho más exactos.

3.1.1.2 Técnicas de aprendizaje no supervisado

De las 8 contribuciones que emplean técnicas de aprendizaje no supervisado (Figura 3.3), el 75 % corresponden a algoritmos de agrupación y el 25 % hacen uso de algoritmos de reducción de la dimensionalidad. Debido a que los algoritmos no supervisados trabajan con conjuntos de datos no etiquetados, los resultados que proporcionan pueden ser menos precisos y con ello, se puede tener dificultades al momento de tratar de solventar problemas o desafíos alrededor de las redes ópticas (ID156). Siendo esta, una posible causa del número inferior de artículos que hacen uso de aprendizaje no supervisado en las investigaciones analizadas. En los algoritmos de agrupación, 4 de las contribuciones codificadas (50 %), hacen uso de técnicas de aprendizaje no supervisado diferentes a las populares, entre ellas encontramos: máquina de vectores de soporte de una clase (ID331, ID452, ID608), bosque

de aislamiento (ID608), naive Bayes de una clase (ID608), autorregresivo lineal (ID778), regresión de vectores de soporte lineal (ID778), las cuales son estrategias no supervisadas, basadas en arquitecturas que emplean técnicas de aprendizaje supervisado (ID778). Estos modelos de ML no supervisado, tienden en su mayoría a tratar de resolver problemas relacionados con la gestión de fallas en una red óptica (ver ID de artículos que abordan técnicas de ML no supervisado vs. problema relacionado con el funcionamiento y operación de redes ópticas, en ANEXO II).




Figura 3.3: Contribuciones que han aportado a la resolución de problemas relacionados con el funcionamiento y operación de redes ópticas con técnicas de aprendizaje no supervisado.

Después de determinar la ubicación y la causa de una falla (algoritmos no supervisados), la estimación de la magnitud de la falla puede proporcionar información adicional para comprender su gravedad y posible solución (algoritmos supervisados) (ID331). A modo de ejemplo, un operador de red luego de identificar una falla, puede decidir si una reconfiguración de la red es suficiente o si es necesaria la reparación o incluso la sustitución de algún equipo del sistema, haciendo uso de técnicas no supervisadas y supervisadas simultáneamente (ID778).

3.1.1.3 Técnicas de aprendizaje semi-supervisado y reforzado

De las 6 contribuciones que emplean técnicas de aprendizaje semi-supervisado (Figura 3.4), el 100 % corresponden a algoritmos de aprendizaje diferentes a los que popularmente se emplean en este tipo de técnicas, entre ellas encontramos: correlación basada en gráficos (ID66, ID109), vector de soporte binario (ID102, ID125), máquina de vectores de soporte de una clase semi-supervisado (ID452), red convolucional gráfica semi-supervisada (ID702) y red antagónica generativa semi-supervisada (ID702), algoritmos que son común-

mente empleados para resolver problemas relacionados con la gestión de fallas en una red óptica (ver ID de artículos que abordan técnicas de ML semi-supervisado vs. problema relacionado con el funcionamiento y operación de redes ópticas, en ANEXO II).




Figura 3.4: Contribuciones que han aportado a la resolución de problemas relacionados con el funcionamiento y operación de redes ópticas con técnicas de aprendizaje semi-supervisado y reforzado.

El objetivo principal de este tipo de técnicas, es tratar de localizar las fallas de un enlace, entrenando datos que describan el estado de la red en incidentes de fallas actuales y pasadas, mediante procesos supervisados y no supervisados de manera simultánea (ID102). Finalmente, se determina que 8 de las contribuciones analizadas, hacen uso de técnicas de aprendizaje reforzado, enfocando su investigación en la administración de recursos de una red óptica (ver ID de artículos que abordan técnicas de ML reforzado vs. problema relacionado con el funcionamiento y operación de redes ópticas, en ANEXO II). Área de trabajo que engloba temas relacionados con la asignación equilibrada de recursos (ancho de banda, espectro óptico, etc.), enrutamiento y asignación de longitud de onda (RWA), entre otros. Desafíos complicados, que requieren de este tipo de técnicas para lograr su adecuado funcionamiento dentro la red (ID291). El aprendizaje reforzado, tiende a lograr resultados mucho más precisos y reales que cualquier otra técnica convencional. Sin embargo, requiere de procesos complejos para su adecuado funcionamiento, siendo esta, una posible causa del número inferior de artículos que hacen uso de aprendizaje reforzado en las investigaciones analizadas.

3.1.2 RQ2—¿QUÉ DESAFÍOS INFORMADOS EN [2], [6], [7] HAN SIDO MAYORITARIAMENTE ABORDADOS MEDIANTE EL USO DE LAS TÉCNICAS DE ML REPORTADAS?

RQ2 busca proporcionar datos sobre qué desafíos o problemas relacionados con el funcionamiento y operación de redes ópticas, han sido abordados mayoritariamente con técnicas

de ML en investigaciones anteriores. Los resultados que permiten dar respuesta a esta pregunta, son discutidos a continuación.

Como se muestra en la Figura 3.5, la mayoría de las contribuciones analizadas (41 artículos), toman como área de investigación el monitoreo de red óptica. Debido a que este desafío, aborda temas relacionados con la supervisión del rendimiento de una red óptica, la estimación de QoT, la gestión de QoE, QoS, entre otros. Que son áreas de importancia que necesitan ser exploradas a través de ML, para lograr maximizar y mejorar el rendimiento de la red para el usuario (ID650).

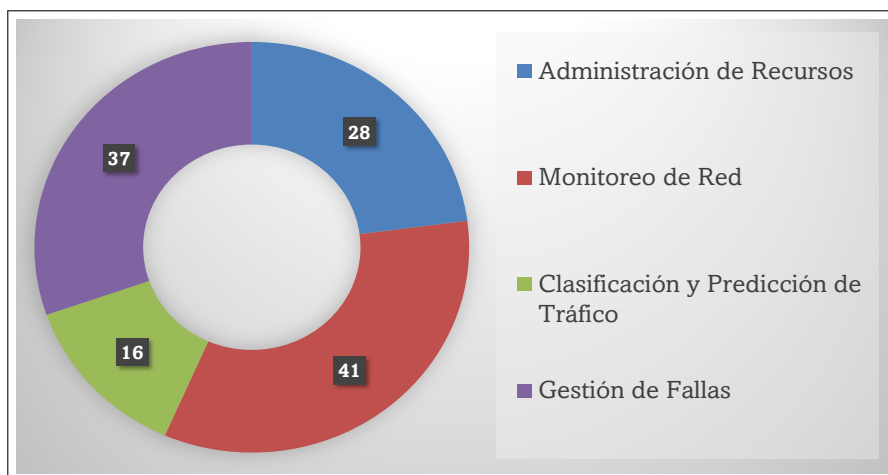


Figura 3.5: Número de contribuciones que abordan algún desafío relacionado con el funcionamiento y operación de redes ópticas haciendo uso de ML.

Adicionalmente, el segundo tema con mayor relevancia en las investigaciones realizadas, se centra en la gestión de fallas en una red óptica (37 artículos). La detección y corrección de fallas es fundamental en este tipo de sistemas, debido a la enorme cantidad de tráfico que soportan las conexiones ópticas. Al aplicar técnicas de ML, existe la posibilidad de identificar la causa del problema lo más pronto posible, para que los recursos fallidos puedan eliminarse del cálculo de las rutas de restauración y así la red de comunicación no se vea afectada por completo (ID16).

Cabe destacar que, aunque se ha trabajado con 96 artículos, algunos de uno de ellos abordan varios desafíos en redes ópticas dentro de una misma investigación. Por lo tanto, la sumatoria de número de artículos por cada desafío reportado, sobrepasa el valor de contribuciones totales que han sido analizadas.

3.1.2.1 Administración de recursos

De los 96 artículos codificados en el presente trabajo, 28 de ellos centran su investigación en el tema de administración de recursos (ver IDs de artículos en ANEXO III). Desafío que

a su vez abarca los siguientes subproblemas:

- Asignación y gestión de recursos ópticos.
- Asignación equilibrada de recursos.
- Asignación de enrutamiento y longitud de onda (RWA).
- Asignación de enrutamiento y espectro (RSA).
- Asignación dinámica adaptativa de longitud de onda y ancho de banda.
- Compartición de espectro.
- Predicción, asignación y supervisión de ancho de banda.

En la Figura 3.6 se visualiza que la mayoría de las investigaciones, han tomado al aprendizaje supervisado (67,86 %) como la técnica de ML apropiada para abordar la administración de recursos en una red óptica.




Figura 3.6: Contribuciones totales por cada técnica de ML reportada para la administración de recursos de una red óptica.

Debido a que, el desafío de enrutamiento y asignación de recursos puede ser visto como un problema de clasificación (ID529). Por lo que 18 artículos (64,29 %), hacen uso de algoritmos de clasificación y tan solo 1 artículo (3,57 %) emplean algoritmos de regresión. Cuando llega un servicio, se requiere enrutar un camino de luz y asignar el recurso en tiempo real según el estado actual de la red. Es decir, cada demanda de tráfico tiene una solución de enrutamiento y asignación de recursos correspondiente. Al ajustar la relación matemática entre los estados de la red y las soluciones de enrutamiento y asignación de recursos, se puede seleccionar de manera inteligente a través de aprendizaje supervisado, la solución apropiada para una nueva solicitud (ID275). Sin embargo, lograr la optimización de este desafío no es una tarea sencilla, ya que su análisis teórico es complejo y emplear técnicas convencionales resultan poco adecuadas para encontrar una adecuada solución (ID143).

Es así que, en ciertas ocasiones, se requiere ayuda de otro tipo de técnicas como aprendizaje reforzado (25 %) y aprendizaje no supervisado (7,14 %) para alcanzar los objetivos propuestos.

3.1.2.2 Monitoreo de red

De los 96 artículos codificados, 41 de ellos centran su investigación en el tema de monitoreo de red (ver IDs de artículos en ANEXO III). Desafío que a su vez abarca los siguientes subproblemas:

- ❑ Monitoreo o supervisión del rendimiento óptico.
- ❑ Estimación, predicción y evaluación de QoT.
- ❑ Estimación de SNR y OSNR.
- ❑ Calidad de servicio (QoS) y calidad de experiencia (QoE).

En la Figura 3.7 se destaca que alrededor del 97,56 % de los 41 artículos, han empleado técnicas de aprendizaje supervisado para abordar este desafío. Mientras que, el 2,44 % hacen uso de aprendizaje no supervisado.




Figura 3.7: Contribuciones totales por cada técnica de ML reportada para el monitoreo de una red óptica.

El monitoreo del rendimiento óptico (OPM), es considerado como la estimación, predicción y adquisición de varios parámetros físicos críticos de las señales ópticas transmitidas y los elementos de la red (QoT, SNR, OSNR, BER, entre otros). De manera que, sus funcionalidades son indispensables para una operación de red confiable y flexible, así como para mejorar su eficiencia (ID59, ID650). Por esa razón, en los últimos años, los algoritmos de aprendizaje supervisado, especialmente las redes neuronales (artificiales, convolucionales y profundas), se han aplicado con éxito para abordar la supervisión rentable de deficiencias

múltiples en redes ópticas (ID255). Adicionalmente, OPM también se considera como una tecnología habilitadora para las redes definidas por software (SDN). Pues a través de OPM, las SDN pueden conocer las condiciones de la red en tiempo real, y posteriormente, ajustar varios parámetros de los elementos de la red (potencias, velocidades de datos, formatos de modulación, etc.), optimizando de mejor manera su rendimiento de transmisión, mediante el uso de arquitecturas basadas en aprendizaje supervisado (ID209).

3.1.2.3 Predicción y clasificación de tráfico

De los 96 artículos codificados, 16 de ellos centran su investigación en el tema de predicción y clasificación de tráfico (ver IDs de artículos en ANEXO III). Desafío que a su vez abarca los siguientes subproblemas:

- ❑ Estimación, clasificación y predicción de flujo de tráfico.
- ❑ Predicción de tráfico a corto y largo plazo.
- ❑ Control de congestión.

En la Figura 3.8 se visualiza que la mayoría de las investigaciones, han tomado al aprendizaje supervisado (81,25%) como la técnica de ML apropiada para abordar el desafío de clasificación y predicción de tráfico en redes ópticas.




Figura 3.8: Contribuciones totales por cada técnica de ML reportada para la clasificación y predicción de tráfico de una red óptica.

Debido a que los datos de tráfico de red son un tipo de datos de series temporales [6], cuya resolución puede ser considerada como un problema de clasificación o regresión (ID43). Por lo que un 75% de los artículos analizados, hacen uso de algoritmos supervisados de clasificación y un 6,25% emplea algoritmos de regresión. La estimación de la distribución del tráfico de una red, es una herramienta importante para evaluar el desempeño de un sistema de comunicaciones. Al analizar los datos de tráfico de la red y extraer sus características,

se pueden explorar sus reglas y sus mecanismos de operación (ID43). En las redes ópticas, debido al cambio de ubicación de acceso del usuario, existe la posibilidad de experimentar un fenómeno de “tráfico de marea” [1], en el que el tráfico de la red cambia en un período de tiempo. Y debido a esto, es posible que se desperdicie el espectro cuando los recursos de la red no se puedan programar de manera flexible en tiempo real [6]. Por lo tanto, cómo estimar de forma rápida el cambio del tráfico de marea y asignar razonablemente los recursos de la red de acuerdo con el tráfico existente, son desafíos clave a resolver con el empleo de aprendizaje supervisado (ID111). Por otra parte, los algoritmos de aprendizaje semi-supervisado (6,25 %) y reforzado (12,5 %), son empleados para la predicción de tráfico de la red, mecanismo esencial y mucho más complejo de analizar y resolver con técnicas de aprendizaje convencionales. El cual beneficia potencialmente a la mejora de la administración de redes ópticas, ya que sirve como base para la asignación de recursos, el re-enrutamiento de tráfico a corto plazo, la planificación de la capacidad a largo plazo, el diseño de la red y la detección de anomalías, mejorando así, la calidad del servicio del usuario (ID702).

3.1.2.4 Gestión de fallas

De los 96 artículos codificados, 37 de ellos centran su investigación en el tema de gestión de fallas (ver IDs de artículos en ANEXO III). Desafío que a su vez abarca los siguientes subproblemas:

- Detección, identificación, localización y gestión de fallas.
- Detección, categorización y localización de fallas blandas (soft) y duras (hard).
- Análisis de alarmas y pronóstico de fallas.
- Métodos de protección y restauración proactiva.
- Detección e identificación de fallas en equipos.

En la Figura 3.9 se destaca que alrededor del 72,97 % de los 37 artículos, han empleado técnicas de aprendizaje supervisado para abordar este problema, ya que el enfoque para tratar este desafío se basa principalmente en un conjunto de clasificadores que hacen

[1] Tráfico de Marea: Con la creciente popularidad de las comunicaciones móviles 5G, la computación en la nube, el streaming de video 4k, etc., la distribución del tráfico de datos se diversifica aún más según la tendencia de las personas a utilizar los servicios de red en diferentes lugares y momentos. Se usa el término de “tráfico de marea” para representar la distribución del tráfico con un fuerte desequilibrio en las dimensiones de tiempo y espacio. El tráfico de marea puede resultar potencialmente en una baja utilización del ancho de banda y una capacidad de servicio débil, ya que los recursos de la red no se asignan correctamente [67].

predicciones utilizando características extraídas del espectro de la señal óptica (ID331).

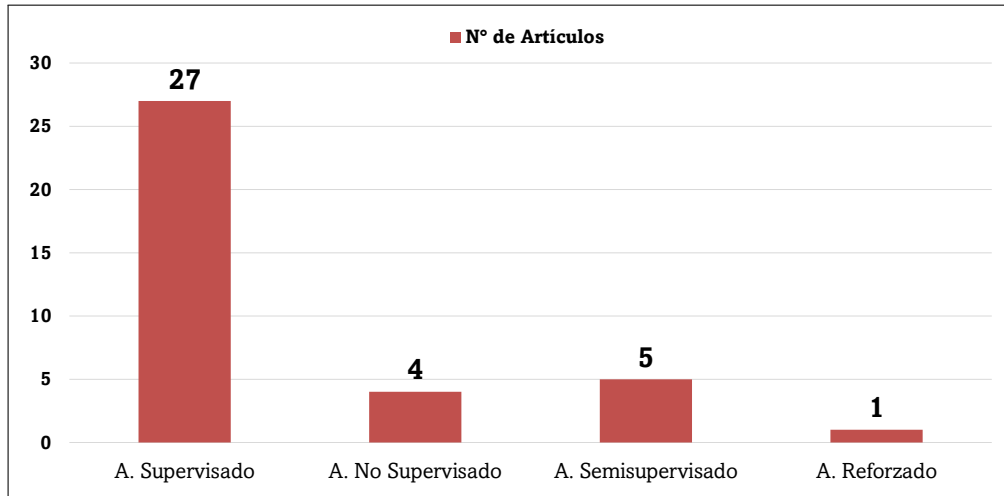


Figura 3.9: Contribuciones totales por cada técnica de ML reportada para la gestión de fallas de una red óptica.

Es así que, los 27 artículos analizados, hacen uso de algoritmos supervisados de clasificación (SVM, K-vecino más cercano, redes neuronales). La gestión de fallas es uno de los desafíos más importantes a tratar, ya que, las fallas pueden provocar una interrupción severa del servicio y la pérdida de la transmisión de datos, degradando así, la calidad de la transmisión (QoT) (ID716). Las fallas en la comunicación de redes ópticas son de dos tipos: fallas blandas (leves) y fallas duras (graves) (ID786). Las fallas graves, son aquellas que conducen inmediatamente a la pérdida del servicio y pueden identificarse fácilmente, por ejemplo: dobleces de fibra, cortes de fibra, entre otros problemas. Mientras que las fallas leves, conducen lentamente a la degradación de la calidad de la señal y reducen la QoT debido a la superposición de señales, desviación del láser, cambio de filtros, interferencias no lineales, ruido, etc. (ID786). Por lo general, las técnicas de ML son utilizada solo para para identificar y estimar fallas leves. Por esta razón, los algoritmos supervisados, no supervisados (10,81 %), semi-supervisados (13,51 %) y reforzados (2,7 %), están brindando soluciones efectivas (mecanismos de alerta temprana, métodos de protección y restauración proactiva de la red óptica) ante este problema.

3.1.3 RQ3—¿QUÉ DATASETS QUE HAN SIDO UTILIZADOS POR LAS TÉCNICAS DE ML EN LOS ARTÍCULOS REVISADOS ESTÁN DISPONIBLES?

RQ3 busca proporcionar datos sobre qué investigaciones anteriores, proveen información (direcciones URL) de los datasets que se han empleado para realizar las pruebas de entrenamiento de los algoritmos de ML. Los resultados que permiten dar respuesta a esta pregunta, son descritos a continuación.

Alrededor del 98,96 % de los artículos analizados, no cuentan con ningún tipo de información acerca de los datasets utilizados para el entrenamiento de los algoritmos de ML. En varios de los artículos, se menciona que se ha trabajado con datasets sintéticos ^[2] (por ejemplo: ID158, ID166, ID473, ID773, ID740, ID786, etc.) y en otras contribuciones, se ha empleado datasets provenientes de redes reales de diferentes locaciones internacionales, para lograr obtener resultados mucho más precisos (por ejemplo: ID129, ID172, ID174, ID200, ID221, ID281, ID361, entre otros). Pero lamentablemente, no se proporciona información alguna acerca de la ubicación de estos datos para que puedan ser empleados en investigaciones futuras. A continuación en la Tabla 3.1, se presentan detalles sobre el único dataset (1,04 %) que se encuentra disponible, el cual ha sido utilizado para abordar el desafío de predicción y clasificación de tráfico a través del uso de técnicas de aprendizaje supervisado.

Tabla 3.1: Información de dataset disponible.

Nombre del Dataset	Descripción	PAPER
SIX (Seattle Internet Exchange)	Proporcionan datos de estadísticas de tráfico entre redes al noroeste de los Estados Unidos. Dirección URL: https://www.seattleix.net/	ID706

3.1.4 RQ4—¿CUÁL ES EL NIVEL DE MADUREZ DE LAS TÉCNICAS DE ML IDENTIFICADAS?

RQ4 busca proporcionar información acerca del nivel de madurez de las técnicas de ML identificadas para solventar desafíos o problemas relacionados con el funcionamiento y operación de redes ópticas, en función de los esfuerzos que han realizado sus autores para evaluar sus investigaciones. Cabe mencionar que, para calificar la madurez de las técnicas de ML identificadas, se ha utilizado los tipos de investigación presentados en el Capítulo 2. Los mismos que establecen a cada contribución, un grado de madurez que va desde un nivel mínimo, cuando un artículo se basa únicamente en opiniones (artículos de experiencia, artículos de opinión y propuestas de solución), hasta un nivel máximo, cuando un artículo ha sido evaluado empíricamente en escenarios reales (investigaciones de validación e investigaciones de evaluación) [56]. Los resultados que permiten dar respuesta a esta pregunta, son discutidos a continuación.

^[2] Datasets sintéticos: Es información generada de manera artificial, que se emplea para entrenar modelos de AI cuando los conjuntos de datos históricos reales son insuficientes o carecen de calidad, volumen o variedad [68].

3.1.4.1 Técnicas de aprendizaje supervisado

Como se visualiza en la Figura 3.10, la mayoría de los desafíos que han sido abordados con técnicas de aprendizaje supervisado (98,96%), se han probado empíricamente. Mientras que el 1,04% restante, no.

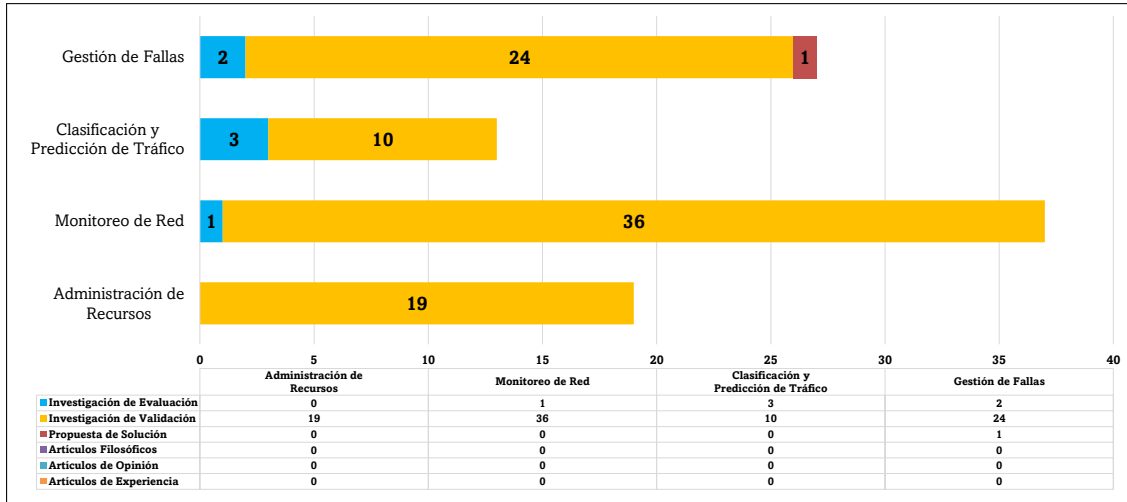


Figura 3.10: Nivel de madurez de técnicas de aprendizaje supervisado (número de artículos por problema).

De manera adicional, de los artículos evaluados de forma empírica, solo 6 artículos (6,25%) han sido valorados en un contexto real (ID43, ID69, ID106, ID174, ID200, ID702). Mientras que la mayoría de ellos (92,71%), fueron validados solamente bajo un entorno de simulación controlado. Por otra parte, entre las técnicas no probadas empíricamente, encontramos tan solo una propuesta de solución (ID156) y ningún artículo filosófico o de opinión. En consecuencia, estos resultados sugieren claramente que las contribuciones sobre las técnicas de aprendizaje supervisado para resolver desafíos o problemas relacionados con el funcionamiento y operación de redes ópticas, tienden a ser propuestas específicas en lugar de abstractas o solo ideas generales. Puesto que la mayoría de los trabajos procuran evaluar la validez de sus contribuciones al menos mediante un ejemplo para dar a conocer la aplicabilidad de su solución. La Figura 3.10 también permite observar el nivel de madurez de las técnicas de aprendizaje supervisado por cada problema, destacándose que para los desafíos de gestión de fallas, monitoreo de red y clasificación y predicción de tráfico, existen artículos probados en entorno real (ID43, ID69, ID106, ID174, ID200, ID702) y evaluados bajo un entorno experimental controlado. Para el desafío de administración de recursos, se presentan solamente contribuciones de validación. Y de manera adicional, para el desafío de gestión de fallas, existe un artículo de propuesta de solución (ID156). Finalmente, se concluye que los algoritmos de aprendizaje supervisado aplicados en la clasificación y pre-

dicción de tráfico, emergen como las técnicas más maduras, ya que sus contribuciones han sido probadas empíricamente (13 artículos), y además, tienen el mayor número de artículos evaluados en un contexto del mundo real (3 de 6 artículos).

3.1.4.2 Técnicas de aprendizaje no supervisado

Como se visualiza en la Figura 3.11, todas las contribuciones que han empleado algoritmos de aprendizaje no supervisado para abordar algún desafío relacionado con el funcionamiento y operación de la redes ópticas, han sido probadas empíricamente.




Figura 3.11: Nivel de madurez de técnicas de aprendizaje no supervisado (número de artículos por problema).

Sin embargo, ninguna de las investigaciones es valorada en un contexto real, sino que fueron validadas solamente bajo un entorno de simulación controlado. Estos resultados indican que, aunque el número de contribuciones que hacen uso de técnicas de aprendizaje no supervisado para solventar desafíos o problemas relacionados con el funcionamiento y operación de redes ópticas es bajo (7 artículos), estos tienden a ser propuestas específicas en lugar de solo ideas generales. La Figura 3.11 también permite visualizar el nivel de madurez de las técnicas de aprendizaje no supervisado por cada problema. En la que se destaca como característica principal que, para los desafíos de gestión de fallas, monitoreo de red y administración de recursos, existen artículos evaluados bajo un entorno experimental controlado. Mientras que el desafío de clasificación y predicción de tráfico, no ha sido tomado en cuenta para ser resuelto mediante técnicas no supervisadas. En consecuencia, se concluye que los algoritmos de aprendizaje no supervisado aplicados a la gestión de fallas, emergen como las técnicas más maduras, ya que sus contribuciones tienen el mayor número de artículos evaluados de manera empírica en un entorno controlado (4 de 7 artículos).

3.1.4.3 Técnicas de aprendizaje semi-supervisado

Como se visualiza en la Figura 3.12, todas las contribuciones que han empleado algoritmos de aprendizaje semi-supervisado para abordar algún desafío relacionado con el funcionamiento y operación de la redes ópticas, han sido probadas empíricamente. De manera adicional, de los artículos evaluados, solo el 16,67 % han sido valorados en un contexto real (ID702). Mientras que la mayoría de ellos (83,33 %), fueron validados solamente bajo un entorno de simulación controlado. Estos resultados evidencian que, aunque el número de contribuciones que hacen uso de técnicas de aprendizaje semi-supervisado para resolver desafíos o problemas relacionados con el funcionamiento y operación de redes ópticas es bajo (6 artículos), estos tienden a ser propuestas específicas en lugar de solo ideas vagas.

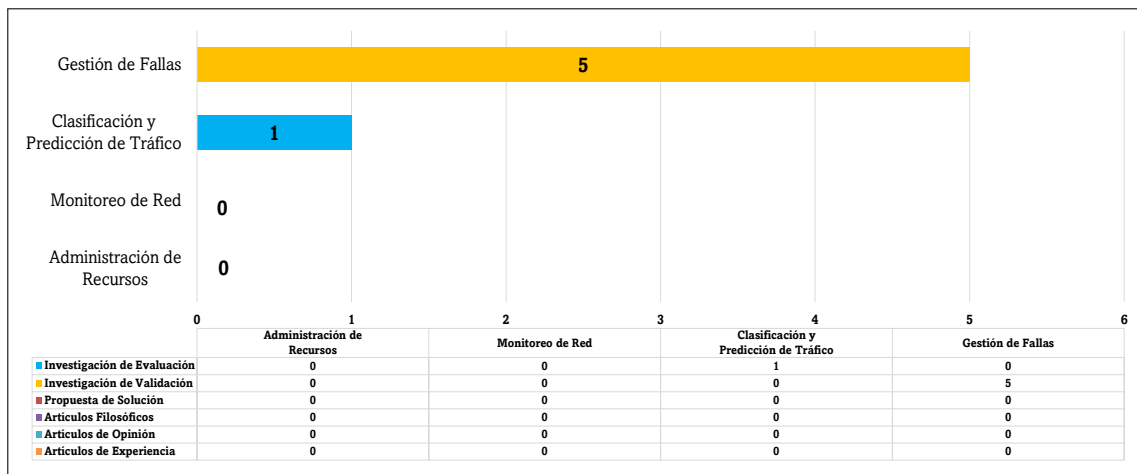


Figura 3.12: Nivel de madurez de técnicas de aprendizaje semi-supervisado (número de artículo por problema).

La Figura 3.12 también permite determinar el nivel de madurez de las técnicas de aprendizaje semi-supervisado por cada problema. En la que se destaca que, para el desafío de clasificación y predicción de tráfico, existe tan solo 1 artículo probado en entorno real. Hay 5 artículos evaluados bajo un entorno experimental controlado que abordan el desafío de gestión de fallas y no existe ningún artículo que reporte técnicas semi-supervisadas para los problemas de monitoreo de red y administración de recursos. Por lo tanto, se concluye que los algoritmos de aprendizaje semi-supervisado aplicados en la clasificación y predicción de tráfico, emergen como las técnicas más maduras, ya que su contribución ha sido evaluada de manera empírica en un contexto del mundo real (ID702).

3.1.4.4 Técnicas de aprendizaje reforzado

Como se visualiza en la Figura 3.13, la mayoría de los desafíos que han sido abordados con técnicas de aprendizaje reforzado (90 %), se han probado empíricamente. Mientras que

el 10 % restante, no.

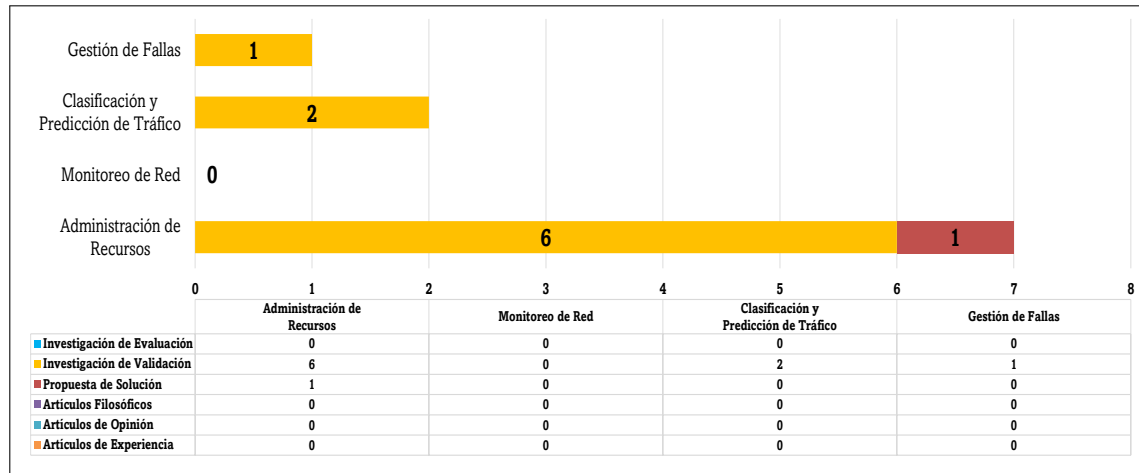


Figura 3.13: Nivel de madurez de técnicas de aprendizaje reforzado (número de artículos por problema).

De manera adicional, de los artículos evaluados de forma empírica, ninguno de ellos ha sido valorado en un contexto real, sino que todos fueron validados solamente bajo un entorno de simulación controlado. Por otra parte, entre las técnicas no probadas empíricamente, encontramos tan solo una propuesta de solución (ID7) y ningún artículo filosófico o de opinión. Por ende, estos resultados indican que, aunque el número de contribuciones que hacen uso de técnicas de aprendizaje reforzado para resolver desafíos o problemas relacionados con el funcionamiento y operación de redes ópticas es bajo (10 artículos), estos tienden a ser propuestas específicas en lugar de solo ideas poco definidas. La Figura 3.13 también permite observar el nivel de madurez de las técnicas de aprendizaje reforzado por cada problema. En la que se destaca que, para los desafíos de gestión de fallas, administración de recursos y clasificación y predicción de tráfico, existen artículos evaluados bajo un entorno experimental controlado. Para el desafío de administración de recursos se presenta de manera adicional un artículo de propuesta de solución y no existe ningún artículo abordado con técnicas reforzadas para el monitoreo de red. Por esta razón, se concluye que los algoritmos de aprendizaje reforzado aplicados a la administración de recursos, emergen como las técnicas más maduras, ya que posee el mayor número de artículos evaluados de manera empírica en un entorno controlado (6 de 9 artículos).

3.1.5 DISCUSIÓN

El análisis de técnicas de ML para solventar problemas relacionados con el funcionamiento y operación de redes ópticas, parece ser un área de investigación prometedora. Puesto que se ha trabajado con artículos a partir del año 2009 (ID7) y además se ha identificado

un interés creciente en esta área, especialmente, en los últimos cinco años. Ya que se visualiza que alrededor de dos tercios (87,5 %) de los artículos codificados en este trabajo, provienen de estos últimos años, como se observa en la Figura 3.14.




Figura 3.14: Distribución de publicaciones por año.

No hay duda alguna de que el uso de algoritmos de ML en el funcionamiento y operación de redes ópticas, están brindando oportunidades sin precedentes a esta área de comunicación. Permitiendo así mejorar aún más su capacidad y confiabilidad, a beneficio de los usuarios.

Durante la codificación de artículos, se identificó que la mayoría de las contribuciones (42.7%), basan su investigación en el área de monitoreo de una red óptica. La creciente demanda de ancho de banda debido a los servicios emergentes como los juegos en línea, streaming, IPTV, entre otros, están obligando a los proveedores de servicios que actualicen sus redes para admitir estas nuevas formas de servicio (ID695). Una solución adecuada ante esta demanda, es emplear redes ópticas debido a sus múltiples ventajas (gran ancho de banda disponible, aproximadamente 100 THz), en comparación con otras tecnologías como RF. Por lo que en un futuro no muy lejano, las redes ópticas admitirán diferentes formatos de modulación y velocidades según el estado del canal y la demanda del cliente final (ID695), convirtiéndose en sistemas cada vez más heterogéneos. Y para gestionar este tipo de redes, será importante la construcción de sistemas de monitoreo de red empleando ML. Los modelos propuestos en las diferentes contribuciones analizadas, proponen que estos algoritmos de ML habiliten la posibilidad de adquisición de información sobre la calidad del enlace físico (parámetros como: QoT, SNR, OSNR, QoS, QoE, etc.), en tiempo real. Para que así la red sea consciente de las deficiencias físicas existentes, logre realizar un diagnóstico propio y cumpla con el acuerdo de calidad de servicio del usuario final de manera dinámica y confiable (ID695).

Así mismo, se ha identificado que la predicción y clasificación de tráfico en una red óptica, es

aquella área de investigación con menor número de contribuciones (16.7%). Según Cisco, la cantidad de usuarios de Internet crecerá de 3,9 en 2018 a 5,3 mil millones en 2023 [69]. Eso, a consecuencia del aumento de dispositivos móviles (celulares, computadoras, tablets, etc.), así como por el surgimiento de IoT y el tan anhelado 5G. El crecimiento desmesurado de usuarios se traduce simplemente en un aumento del tráfico de la red. En la actualidad, los medios de comunicación utilizados como redes troncales, que permiten el transporte de una gran cantidad de tráfico de datos de usuario, son las redes ópticas (ID498). Tener un conocimiento previo sobre el tráfico de la red, puede resultar de gran ventaja para los operadores, ya que así existe la posibilidad de disminuir los costos operativos de la red debido a una gestión eficiente de sus recursos (ID498). El número reducido de artículos que abordan este tema (16 de 96 artículos), no es a consecuencia de que es un área de investigación que no aporte beneficio con el funcionamiento y operación de redes ópticas. Ya que como se ha mencionado previamente, todo incremento de usuarios se convierte en tráfico para la red y necesita ser controlado de manera correcta para evitar contratiempos a los usuarios. El problema se centra en que, los algoritmos de ML que se pueden emplear para pronosticar el tráfico con alta precisión, requieren de datos de entrenamiento acorde a las redes reales para que puedan ser métodos confiables. ML puede modelar flujos de tráfico, continuos, regulares, que cambien en el tiempo y usar esos datos en entrenamiento para predecir futuros flujos de datos de una red (ID471). No obstante, en un verdadero dataset de tráfico de red, se pueden observar patrones diarios y semanales de las actividades cotidianas de los usuarios, con lo que los algoritmos de ML pueden pronosticar, encontrar, analizar y usar esos datos para predecir futuros flujos de datos de red acorde a la realidad. Sin embargo, proveedores y operadores de red, no comparten este tipo de información con terceros, ya que podría contener datos confidenciales de sus usuarios finales.

Finalmente, se desea argumentar que, la idea de implementar estos métodos basados en ML en redes de comunicaciones reales, resulta aún muy difícil. Ya que para lograr el despliegue exitoso de técnicas de ML en redes ópticas, aún quedan muchos desafíos por resolver. A continuación, se dan a conocer algunas de las brechas identificadas durante la realización de este proyecto y que se cree que requerirán más atención durante los próximos años en investigaciones futuras.

1. **Disponibilidad de datasets:** Durante la codificación de los 96 artículos analizados, solo se encontró disponible la información de un dataset empleado para tratar el problema de clasificación y predicción de tráfico (ID706). Siendo esto, un causante de

no lograr un despliegue exitoso de métodos basados en ML en el funcionamiento y operación de redes ópticas reales. Ya que no existe la posibilidad de que los datos sean empleados en nuevas investigaciones, limitando así, esta área de estudio prometedora.

2. **Datasets sintéticos:** Se identificó que la mayoría de los artículos hacen uso de datasets sintéticos para la evaluación experimental de su método creado. Los datos sintéticos son mucho menos costosos de generar, pero pueden tener mucho más sesgo y ser menos precisos que los datos del mundo real. La calidad del modelo de ML desarrollado, depende de la fuente de datos de entrenamiento que se le proporcione. Al trabajar con datos sintéticos, aunque el algoritmo de ML arroje resultados positivos durante su fase de prueba, si se lo implementa en un escenario real, es posible que sus resultados varíen, puesto que, reproducir la diversidad de escenarios de una red real en un entorno de laboratorio, es improbable. Adicionalmente, se puede mencionar que se trabaja con datasets sintéticos, ya que es difícil que proveedores y operadores de red revelen un gran conjunto de datos de campo para probar la practicidad de alguna solución que se encuentre en estudio.
3. **Metodologías de ML:** Existen dos tipos de metodologías: online y offline. El ML online, es aquel que tiene lugar a medida que los datos están disponibles. Es decir, el modelo puede aprender de la nueva información en tiempo real tan pronto como llega. Mientras que el ML offline, es exactamente lo opuesto al aprendizaje online. Porque el modelo no puede aprender de manera incremental a partir de un flujo de datos en vivo. Si bien el aprendizaje online tiene sus usos, el aprendizaje automático tradicional se lo realiza de manera offline [70]. Durante la codificación de los artículos analizados, se ha identificado que la gran mayoría de ellos utilizan métodos de ML offline para el desarrollo de sus investigaciones. Suposición que puede estar alejada de la realidad en redes ópticas, ya que este tipo de redes, evolucionan constantemente con el tiempo debido a variaciones del tráfico, cambios en el comportamiento de los componentes ópticos, entre otros [70]. Por lo tanto, si el método de ML solamente se ha entrenado bajo un conjunto de datos proporcionados por una determinada topología, este método no podría operar de manera correcta si se lo aplica a una topología diferente o modificada. Limitando así, el despliegue exitoso de soluciones basadas en ML para el funcionamiento y operación de redes ópticas reales.
4. **Visualización de datos:** Durante la codificación de los artículos, se identificó que existe poco desarrollo de herramientas de visualización que permitan comprender de

manera sencilla a los usuarios, la información producida por los algoritmos de ML. Por lo que solventar este desafío, es clave para la integración perfecta de los métodos de ML en la administración de redes ópticas. Aunque se identificó un artículo que desarrolla algunos pasos de investigación en esta dirección (ID156), donde se emplean el algoritmo K-means para agrupar los datos de seguimiento de BER de lightpaths (caminos de luz), este reto requiere de mucha más investigación a futuro.

3.2 CONCLUSIONES

El presente proyecto codificó 96 artículos de las 841 publicaciones obtenidas a partir de la base de datos de Scopus. Con el propósito de encontrar información relevante que permita cumplir con los objetivos planteados en el trabajo y responder a las 4 preguntas de investigación (RQs) definidas durante este estudio. Luego de la finalización de la investigación realizada, se concluye que el principal resultado de este mapeo sistemático de literatura, es la identificación y clasificación de las técnicas de ML existentes que abordan desafíos relacionados con el funcionamiento y operación de redes ópticas. A la vez que se detalla el nivel de madurez de las diferentes técnicas, se identifica oportunidades, brechas y se sugiere futuras líneas de investigación.

Se identifica que la mayoría de los artículos examinados (95.8%), hacen uso de aprendizaje supervisado para abordar temas relacionados con la administración de recursos, monitoreo de red, gestión de fallas, clasificación y predicción de tráfico de una red óptica. A consecuencia de que las soluciones generadas por los métodos supervisados son más precisas y confiables en comparación con las soluciones producidas por las técnicas no supervisadas y semi-supervisadas. Además de que, el proceso de entrenamiento de los algoritmos supervisados es menos complejo que al trabajar con algoritmos de aprendizaje por refuerzo. Debido a que estos últimos, requieren mucho más cálculos, lo que puede conducir a una sobrecarga de estados en el proceso de entrenamiento y generar una disminución en la exactitud de los resultados deseados.

Se determina que el desafío al que se ha destinado mayores esfuerzos de investigación es al de monitoreo de red, debido a que abarca subproblemas relacionados con OPM, QoT, SNR, OSNR, QoS, QoE, etc., parámetros que son indispensables para una operación de red confiable y flexible, así como para mejorar su eficiencia. Por esa razón, en los últimos años, los algoritmos de aprendizaje supervisado, especialmente las redes neuronales (artificiales, convolucionales y profundas), se han aplicado con éxito para abordar la supervisión rentable

de deficiencias múltiples en redes ópticas.

Aunque el uso de algoritmos de ML en el funcionamiento y operación de redes ópticas están brindando oportunidades sin precedentes a esta área de comunicación. Se puede identificar que aún existen brechas que impiden la posibilidad de aplicar estos métodos desarrollados en redes de comunicaciones reales. La disponibilidad de datasets para trabajos futuros, empleo de datos reales en lugar de datos sintéticos, aprendizaje automático online en entrenamiento de algoritmos y mejora de la visualización de datos para el usuario final, son algunos de los desafíos identificados y que necesitan ser explorados a futuro. Con ello, es posible mejorar el nivel de madurez de las técnicas empleadas en las diferentes investigaciones relacionadas a este campo. Ya que la mayoría de las contribuciones, tienden a ser artículos de validación. Es decir, los modelos propuestos están solamente sometidos a pruebas experimentales en ambientes controlados y más no probados en redes ópticas reales.

3.3 RECOMENDACIONES

Una adecuada organización durante la etapa de planificación, permite cumplir con éxito los objetivos planteados en el proyecto. Se sugiere desarrollar documentación adicional en Word y en Excel, que permitan una mejor distribución de las ideas que formarán parte del trabajo escrito final, como se lo presenta en el ANEXO I. Adicionalmente, durante la etapa de selección y codificación de los artículos obtenidos a partir de Scopus, se propone emplear herramientas gratuitas (CADIMA) o pagadas (NVIVO) que permitan reducir el tiempo de procesamiento de información y organizar los datos obtenidos de una mejor manera.

Durante la definición de la cadena de búsqueda y criterios de inclusión-exclusión automatizada y manual del estudio de mapeo sistemático, se debe tomar en cuenta sus Amenazas a la Validez (Threats to validity). Aunque se siga cuidadosamente el estudio de mapeo sistemático, para minimizar las amenazas a la validez de los resultados y las conclusiones extraídas en este documento, hay algunos desafíos que se deben enfrentar en sus diferentes etapas.

- ❑ **Amenazas Interna:** El sesgo de un investigador individual en decidir si incluir o excluir un trabajo candidato, clasificarlo de acuerdo con el esquema construido y analizar los resultados, son amenazas internas inherentes al estudio que podrían conducir a resultados erróneos [56]. En este trabajo, para mitigar estas amenazas se tomaron varias medidas. Se estandarizó los criterios en todo el equipo de investigación (tutor y estudiante) para garantizar una comprensión similar y un 20 % de todos los artículos

fueron revisados por al menos dos investigadores (tutor y estudiante). Con respecto a la aplicación de los criterios de inclusión y exclusión durante el procedimiento de selección, el equipo de investigación (tutor y estudiante) llevó a cabo un piloto iterativo, destinado a validar los criterios y normalizar su comprensión. Pasando a la fase principal, tras alcanzar un coeficiente de fiabilidad igual o mayor a 0,8. En cuanto al procedimiento de codificación, se hizo un gran esfuerzo para construir un esquema de clasificación adecuado para ordenar consistentemente la información de los 96 artículos. Por lo tanto, este esquema se construyó utilizando clasificaciones reconocidas existentes y refinándolas para evitar errores de clasificación posteriores. Finalmente, para analizar los resultados, generar gráficos y sacar conclusiones, se basó directamente a partir de los hallazgos, observaciones y tendencias explícitas encontradas durante la investigación.

- **Amenazas Externas:** La falta de consenso cuando los investigadores se refieren al dominio abordado en este estudio (por ejemplo: Redes Ópticas frente a Comunicaciones Ópticas) podría conducir a una generalización errónea de los hallazgos obtenidos sino se realiza una planificación adecuada del proyecto a realizarse [56]. Para mitigar estas amenazas, se ha realizado un trabajo exhaustivo que consta de varias medidas. Los resultados y conclusiones de este proyecto solo son válidos para las técnicas que caen dentro del alcance definido en el estudio. Es decir, técnicas de ML para solventar problemas relacionados con el funcionamiento y operaciones de redes ópticas reportados en [2], [6], [7]. Se ha realizado un gran esfuerzo para describir minuciosamente la etapa de planificación del estudio de mapeo sistemático—definición detallada de las preguntas de investigación, selección de criterios de inclusión y exclusión, esquema de clasificación— garantizando la confiabilidad del estudio.

4 REFERENCIAS BIBLIOGRÁFICAS

- [1] F. Musumeci, C. Rottondi, A. Nag et al., "An Overview on Application of Machine Learning Techniques in Optical Networks," *IEEE Communications Surveys and Tutorials*, vol. 21, págs. 1383-1408, 2 abr. de 2019, ISSN: 1553877X. DOI: 10.1109/COMST.2018.2880039.
- [2] R. Gu, Z. Yang e Y. Ji, "Machine learning for intelligent optical networks: A comprehensive survey," *Journal of Network and Computer Applications*, vol. 157, pág. 102576, mayo de 2020, ISSN: 1084-8045. DOI: 10.1016/J.JNCA.2020.102576.
- [3] *What is Quality of Service (QoS) in Networking? | Fortinet.* dirección: <https://www.fortinet.com/resources/cyberglossary/qos-quality-of-service>.
- [4] *What is QoE (Quality of Experience) QoE Meaning? | Axiros.* dirección: <https://www.axiros.com/knowledge-base/qoe-quality-of-experience>.
- [5] L. Zhang, X. Li, Y. Tang, J. Xin y S. Huang, "A survey on QoT prediction using machine learning in optical networks," *Optical Fiber Technology*, vol. 68, pág. 102804, ene. de 2022, ISSN: 1068-5200. DOI: 10.1016/J.YOFTE.2021.102804.
- [6] Y. Zhang, J. Xin, X. Li y S. Huang, "Overview on routing and resource allocation based machine learning in optical networks," *Optical Fiber Technology*, vol. 60, dic. de 2020, ISSN: 10685200. DOI: 10.1016/j.yofte.2020.102355.
- [7] R. Boutaba, M. A. Salahuddin, N. Limam et al., "A comprehensive survey on machine learning for networking: evolution, applications and research opportunities," *Journal of Internet Services and Applications*, vol. 9, 1 dic. de 2018, ISSN: 18690238. DOI: 10.1186/s13174-018-0087-2.
- [8] *AI and ML in Networking: Sci-Fi is Becoming Reality - Planet Technology USA.* dirección: <https://planetechusa.com/artificial-intelligence/>.
- [9] *What Is Artificial Intelligence (AI) in Networking? - Cisco.* dirección: <https://www.cisco.com/c/en/us/solutions/artificial-intelligence/artificial-intelligence-machine-learning-in-networking.html>.
- [10] *SolarWinds Network Performance Monitor.* dirección: <https://www.e-dea.co/network-performance-monitor>.
- [11] *AI ML in Network Management: How are they integrating in Networks?* Dirección: https://www.comparitech.com/net-admin/ai-ml-in-network-management/#AI_and_ML_in_network_management.

- [12] *What is the role of machine learning in networking?* Dirección: <https://www.techtarget.com/searchnetworking/answer/What-is-the-role-of-machine-learning-in-networking>.
- [13] *Using Artificial Intelligence in Cybersecurity | Balbix.* dirección: <https://www.balbix.com/insights/artificial-intelligence-in-cybersecurity/>.
- [14] *What is phishing? Everything you need to know | IT Governance UK.* dirección: <https://www.itgovernance.co.uk/phishing>.
- [15] R. Gu, Z. Yang e Y. Ji, "Machine learning for intelligent optical networks: A comprehensive survey," *Journal of Network and Computer Applications*, vol. 157, pág. 102576, mayo de 2020, ISSN: 1084-8045. DOI: 10.1016/J.JNCA.2020.102576.
- [16] J. Gordon, A. Battou, M. Majurski et al., "Summary: Workshop on Machine Learning for Optical Communication Systems," mar. de 2020. DOI: 10.6028/NIST.SP.2100-04. dirección: <https://nvlpubs.nist.gov/nistpubs/SpecialPublications/NIST.SP.2100-04.pdf>.
- [17] *What is Feature Engineering — Importance, Tools and Techniques for Machine Learning | by Harshil Patel | Towards Data Science.* dirección: <https://towardsdatascience.com/what-is-feature-engineering-importance-tools-and-techniques-for-machine-learning-2080b0269f10>.
- [18] Y. Lecun, Y. Bengio y G. Hinton, "Deep learning," *Nature 2015 521:7553*, vol. 521, págs. 436-444, 7553 mayo de 2015, ISSN: 1476-4687. DOI: 10.1038/nature14539. dirección: <https://www.nature.com/articles/nature14539>.
- [19] *Que es un diagrama de ojo - programador clic.* dirección: <https://programmerclick.com/article/50171415791/>.
- [20] D. Wang, M. Zhang, Z. Li et al., "Convolutional Neural Network-Based Deep Learning for Intelligent OSNR Estimation on Eye Diagrams," *European Conference on Optical Communication, ECOC*, vol. 2017-September, págs. 1-3, sep. de 2017. DOI: 10.1109/ECOC.2017.8345925.
- [21] R. Masoudi y A. Ghaffari, "Software defined networks: A survey," *Journal of Network and Computer Applications*, vol. 67, págs. 1-25, mayo de 2016, ISSN: 10958592. DOI: 10.1016/J.JNCA.2016.03.016.
- [22] Y. Ji, H. Wang, J. Cui, M. Yu, Z. Yang y L. Bai, "All-optical signal processing technologies in flexible optical networks," *Photonic Network Communications 2019 38:1*, vol. 38, págs. 14-36, 1 mar. de 2019, ISSN: 1572-8188. DOI: 10.1007/S11107-019-00838-Y. dirección: <https://link.springer.com/article/10.1007/s11107-019-00838-y>.

- [23] *TOP 5 Machine Learning Algorithms For Business Applications*. dirección: <https://mobidev.biz/blog/5-essential-machine-learning-techniques>.
- [24] *What is Supervised Learning? | IBM*. dirección: <https://www.ibm.com/cloud/learn/supervised-learning>.
- [25] *TOP 5 Machine Learning Algorithms For Business Applications*. dirección: <https://mobidev.biz/blog/5-essential-machine-learning-techniques>.
- [26] *10 Machine Learning Methods that Every Data Scientist Should Know | by Jorge Castañón | Towards Data Science*. dirección: <https://towardsdatascience.com/10-machine-learning-methods-that-every-data-scientist-should-know-3cc96e0e0e0e9>.
- [27] *| Xoriant*. dirección: <https://www.xoriant.com/blog/product-engineering/decision-trees-machine-learning-algorithm.html>.
- [28] *Difference Between Classification and Regression in Machine Learning*. dirección: <https://machinelearningmastery.com/classification-versus-regression-in-machine-learning/>.
- [29] *Acerca de la regresión lineal - México | IBM*. dirección: <https://www.ibm.com/mx-es/analytics/learn/linear-regression>.
- [30] *Understanding Polynomial Regression!!! | by Abhigyan | Analytics Vidhya | Medium*. dirección: <https://medium.com/analytics-vidhya/understanding-polynomial-regression-5ac25b970e18>.
- [31] *Aprendizaje supervisado y no supervisado - healthdataminer.com*. dirección: <https://healthdataminer.com/data-mining/aprendizaje-supervisado-y-no-supervisado/>.
- [32] *Unsupervised Machine Learning: Algorithms, Types with Example*. dirección: <https://www.guru99.com/unsupervised-machine-learning.html>.
- [33] *K-means Clustering: Algorithm, Applications, Evaluation Methods, and Drawbacks | by Imad Dabbura | Towards Data Science*. dirección: <https://towardsdatascience.com/k-means-clustering-algorithm-applications-evaluation-methods-and-drawbacks-aa03e644b48a>.
- [34] *Fuzzy K-Means Clustering in Mahout*. dirección: https://www.edureka.co/blog/fuzzy_k-means/.
- [35] *What is Unsupervised Learning? | IBM*. dirección: <https://www.ibm.com/cloud/learn/unsupervised-learning>.

- [36] *Gaussian Mixture Models: What are they when to use?* - Data Analytics. dirección: <https://vitalflux.com/gaussian-mixture-models-what-are-they-when-to-use/>.
- [37] *¿Qué es machine learning?* - España | IBM. dirección: <https://www.ibm.com/es-es/cloud/learn/machine-learning>.
- [38] *Semi-Supervised Learning, Explained* | AltexSoft. dirección: <https://www.altexsoft.com/blog/semi-supervised-learning/>.
- [39] *What are the types of Reinforcement learning algorithms?* - FinsliQ Blog. dirección: <https://www.finsliqblog.com/ai-and-machine-learning/what-are-the-types-of-reinforcement-learning-algorithms/>.
- [40] *Aprendizaje profundo por refuerzo* - IIC. dirección: <https://www.iic.uam.es/aprendizaje-profundo-por-refuerzo/>.
- [41] *Overview of Network Resource Management - Managing Network Virtualization and Network Resources in Oracle® Solaris 11.2.* dirección: https://docs.oracle.com/cd/E36784_01/html/E36813/gecki.html.
- [42] *What Is Network Virtualization and Network Resource Management?* - Managing Network Virtualization and Network Resources in Oracle® Solaris 11.2. dirección: https://docs.oracle.com/cd/E36784_01/html/E36813/gndac.html.
- [43] O. Brun, S. Baraketi, O. Brun y S. Baraketi, "Routing and Wavelength Assignment in Optical Networks," 2014. dirección: <https://hal.science/hal-01062321>.
- [44] *What is Network Performance Monitoring?* Dirección: <https://www.techtarget.com/searchnetworking/definition/network-performance-monitoring>.
- [45] *What is Network Performance Monitoring? Definition and FAQs* | HEAVY.AI. dirección: <https://www.heavy.ai/technical-glossary/network-performance-monitoring>.
- [46] R. Vinayakumar, K. P. Soman y P. Poornachandran, "Applying deep learning approaches for network traffic prediction," *2017 International Conference on Advances in Computing, Communications and Informatics, ICACCI 2017*, vol. 2017-January, págs. 2353-2358, nov. de 2017. DOI: 10.1109/ICACCI.2017.8126198.
- [47] *Overview of traffic prediction system and its impact on TMS efficiency* | Download Scientific Diagram. dirección: https://www.researchgate.net/figure/Overview-of-traffic-prediction-system-and-its-impact-on-TMS-efficiency_fig5_266673838.

- [48] M. M. Raikar, S. M. Meena, M. M. Mulla, N. S. Shetti y M. Karanandi, "Data Traffic Classification in Software Defined Networks (SDN) using supervised-learning," *Procedia Computer Science*, vol. 171, págs. 2750-2759, ene. de 2020, ISSN: 1877-0509. DOI: 10.1016/J.PROCS.2020.04.299.
- [49] S. Valenti, D. Rossi, A. Dainotti, A. Pescapè, A. Finamore y M. Mellia, "Reviewing traffic classification," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 7754, págs. 123-147, 2013, ISSN: 16113349. DOI: 10.1007/978-3-642-36784-7_6/COVER. dirección: https://link.springer.com/chapter/10.1007/978-3-642-36784-7_6.
- [50] *6.1 Issues in Resource Allocation — Computer Networks: A Systems Approach Version 6.2-dev documentation*. dirección: <https://book.systemsapproach.org/congestion/issues.html>.
- [51] *Network Fault Management and Monitoring Tools - ManageEngine OpManager*. dirección: <https://www.manageengine.com/network-monitoring/network-fault-management.html>.
- [52] C. Z. Liu y M. Kavakli, "Data-aware QoE-QoS management," *Proceedings of the 2016 IEEE 11th Conference on Industrial Electronics and Applications, ICIEA 2016*, págs. 1818-1823, oct. de 2016. DOI: 10.1109/ICIEA.2016.7603882.
- [53] *The quality of transmission depends upon*: dirección: <https://www.toppr.com/ask/question/the-quality-of-transmission-depends-upon/>.
- [54] C. Rottondi, L. Barletta, A. Giusti y M. Tornatore, "Machine-Learning Method for Quality of Transmission Prediction of Unestablished Lightpaths," *Journal of Optical Communications and Networking, Vol. 10, Issue 2, pp. A286-A297*, vol. 10, A286-A297, 2 feb. de 2018, ISSN: 1943-0639. DOI: 10.1364/JOCN.10.00A286. dirección: <https://opg.optica.org/viewmedia.cfm?uri=jocn-10-2-A286&seq=0&html=true%20https://opg.optica.org/abstract.cfm?uri=jocn-10-2-A286%20https://opg.optica.org/jocn/abstract.cfm?uri=jocn-10-2-A286>.
- [55] K. Petersen, S. Vakkalanka y L. Kuzniarz, "Guidelines for conducting systematic mapping studies in software engineering: An update," *Information and Software Technology*, vol. 64, págs. 1-18, ago. de 2015, ISSN: 09505849. DOI: 10.1016/j.infsof.2015.03.007.

- [56] D. S. Guaman, J. M. Alamo y J. C. Caiza, "A Systematic Mapping Study on Software Quality Control Techniques for Assessing Privacy in Information Systems," *IEEE Access*, vol. 8, págs. 74 808-74 833, 2020, ISSN: 21693536. DOI: 10.1109/ACCESS.2020.2988408.
- [57] P. Mongeon y A. Paul-Hus, "The journal coverage of Web of Science and Scopus: a comparative analysis," *Scientometrics 2015 106:1*, vol. 106, págs. 213-228, 1 oct. de 2015, ISSN: 1588-2861. DOI: 10.1007/S11192-015-1765-5. dirección: <https://link.springer.com/article/10.1007/s11192-015-1765-5>.
- [58] L. G. Stein, "Las fuentes secundarias," dirección: www.ts.ucr.ac.cr.
- [59] *Clasificación general de las fuentes de información | Biblioteca Virtual del Sistema de Universidad Virtual*. dirección: <http://biblioteca.udgvirtual.udg.mx/portal/clasificacion-general-de-las-fuentes-de-informacion>.
- [60] *CADIMA*. dirección: <https://www.cadima.info/>.
- [61] C. Kohl, E. J. McIntosh, S. Unger et al., "Online tools supporting the conduct and reporting of systematic reviews and systematic maps: A case study on CADIMA and review of existing tools," *Environmental Evidence*, vol. 7, págs. 1-17, 1 feb. de 2018, ISSN: 20472382. DOI: 10.1186/S13750-018-0115-5/TABLES/3. dirección: <https://environmentalevidencejournal.biomedcentral.com/articles/10.1186/s13750-018-0115-5>.
- [62] (14) (PDF) *On Krippendorff's Alpha Coefficient*. dirección: https://www.researchgate.net/publication/267823285_On_Krippendorff's_Alpha_Coefficient.
- [63] *Inter-rater Reliability Metrics: An Introduction to Krippendorff's Alpha*. dirección: <https://www.surgehq.ai/blog/inter-rater-reliability-metrics-an-introduction-to-krippendorffs-alpha>.
- [64] K. Krippendorff, "Reliability in Content Analysis: Some Common Misconceptions and Recommendations," 2004. dirección: <http://repository.upenn.edu/ascpapers/242>.
- [65] R. Wieringa, N. Maiden, N. Mead y C. Rolland, "Requirements engineering paper classification and evaluation criteria: A proposal and a discussion," *Requirements engineering*, vol. 11, págs. 102-107, 1 mar. de 2006, ISSN: 0947-3602. DOI: 10.1007/S00766-005-0021-6. dirección: <https://research.utwente.nl/en/publications/requirements-engineering-paper-classification-and-evaluation-crit>.

- [66] “Introducción al trabajo con NVivo 12,” dirección: http://www.uptc.edu.co/export/sites/default/eventos/2019/sf/doc/guia_nvivo.pdf.
- [67] B. Yan, Y. Zhao, X. Yu et al., “Tidal-traffic-aware routing and spectrum allocation in elastic optical networks,” *Journal of Optical Communications and Networking*, vol. 10, págs. 832-842, 11 nov. de 2018, ISSN: 19430620. DOI: 10.1364/JOCN.10.000832.
- [68] *¿Qué son los datos sintéticos? Datos generados para ayudar a tu estrategia de IA / BIG DATA / CIO.* dirección: <https://www.ciospain.es/big-data/que-son-los-datos-sinteticos-datos-generados-para-ayudar-a-tu-estrategia-de-ia>.
- [69] *Cisco Annual Internet Report - Cisco Annual Internet Report (2018–2023) White Paper - Cisco.* dirección: <https://www.cisco.com/c/en/us/solutions/collateral/executive-perspectives/annual-internet-report/white-paper-c11-741490.html>.
- [70] *Online vs offline machine learning – what’s the difference? | Qwak’s Blog.* dirección: <https://www.qwak.com/post/online-vs-offline-machine-learning-whats-the-difference>.

5 ANEXOS

Los anexos que forman parte del proyecto son:

I ANEXO I: BASE DE DATOS Y DOCUMENTOS GENERADOS EN LA ETAPA DE PLANIFICACIÓN.

Las evidencias de documentos utilizados en la ejecución de este proyecto se encuentran cargados en el siguiente repositorio:

<https://github.com/gene9804/ML-for-Optical-Network>

II ANEXO II: ID DE TÉCNICAS DE ML VS PROBLEMA EN REDES ÓPTICAS ABORDADO

Tabla I: Técnicas de ML empleadas vs Problema abordado.

APRENDIZAJE SUPERVISADO (92)					
		P1: Administración de Recursos	P2: Monitoreo de Red	P3: Clasificación y Predicción de Tráfico	P4: Gestión de Fallas
CLASIFICACIÓN (83)	Regresión Logística (0)	---	---	---	---
	SVM (8)	ID92, ID529	ID650	---	ID69, ID156, ID452, ID574, ID816
	Árbol de decisión (1)	ID558	---	---	---
	K-vecino más cercano (2)	ID491	---	---	ID200
	Bosque aleatorio (0)	---	---	---	---
	Redes Neuronales (32)	ID129, ID136, ID139, ID172, ID242, ID262, ID275, ID283, ID464, ID827	ID79, ID114, ID139, ID221, ID228, ID255, ID256, ID281, ID478, ID581, ID697, ID720, ID726, ID736, ID787	ID43, ID72, ID139, ID151, ID172, ID174	ID114, ID172, ID228, ID461, ID648, ID786, ID820
	Naive Bayes (4)	---	---	ID111	ID36, ID67, ID677
	Múltiple (26)	ID267, ID396, ID595	ID59, ID158, ID163, ID166, ID189, ID209, ID267, ID457, ID519, ID638, ID733, ID740, ID765, ID814	ID306, ID498, ID706	ID102, ID125, ID128, ID318, ID331, ID420, ID470
	Otros (10)	ID339	ID106, ID107, ID361	ID471, ID702	ID16, ID66, ID109, ID716
REGRESIÓN (9)	Regresión lineal (2)	ID352	ID189	---	---
	Regresión polinomial (0)	---	---	---	---
	Múltiple (0)	---	---	---	---
	Otros (7)	---	ID207, ID473, ID519, ID650, ID670, ID695	ID706	---
APRENDIZAJE NO SUPERVISADO (8)					
AGRUPACIÓN (6)	K-means (2)	ID529	---	ID156	---
	K-means suave o difuso (0)	---	---	---	---
	HCA (0)	---	---	---	---
	Modelo de Mezcla Gaussiana (0)	---	---	---	---
	Múltiple (0)	---	---	---	---
	Otros (4)	---	ID608	---	ID331, ID452, ID778
ASOCIACIÓN (0)	Algoritmos A priori (0)	---	---	---	---
	Múltiple (0)	---	---	---	---
	Otros (0)	---	---	---	---
REDUCCIÓN DE DIMENSIONALIDAD (2)	PCA (1)	ID92	---	---	---
	SVD (0)	---	---	---	---
	Codificadores Automáticos (1)	---	---	---	ID574
	Múltiple (0)	---	---	---	---
	Otros (0)	---	---	---	---
APRENDIZAJE SEMISUPERVISADO (6)					
Auto-entrenamiento (0)		---	---	---	---
Co-entrenamiento (0)		---	---	---	---
Propagación de Etiquetas Basada en Gráficos (0)		---	---	---	---
Múltiple (0)		---	---	---	---
Otros (6)		---	---	ID702	ID66, ID102, ID109, ID125, ID452
APRENDIZAJE REFORZADO (8)					
Positivo (6)		ID7, ID29, ID172, ID262, ID291	---	ID172, ID533	ID172
Negativo (0)		---	---	---	---
Profundo (0)		---	---	---	---
Múltiple (2)		ID143, ID455	---	---	---
Otros (0)		---	---	---	---

III ANEXO III: ID DE DESAFÍOS EN REDES ÓPTICA VS TÉCNICA DE ML EMPLEADA

Tabla I: Desafío en Redes Óptica vs Técnica de ML empleada.

ADMINISTRACIÓN DE RECURSOS (28)			
APRENDIZAJE SUPERVISADO (19)			
CLASIFICACIÓN (18)	SVM	2	ID92, ID529
	Árbol de decisión	1	ID558
	K-vecino más cercano	1	ID491
	Redes Neuronales	10	ID129, ID136, ID139, ID172, ID242, ID262, ID275, ID283, ID464, ID827
	Múltiple	3	ID267, ID396, ID595
	Otros	1	ID339
REGRESIÓN (1)	Regresión lineal	1	ID352
APRENDIZAJE NO SUPERVISADO (2)			
AGRUPACIÓN (1)	K-means	1	ID529
REDUCCIÓN DE DIMENSIONALIDAD (1)	PCA	1	ID92
APRENDIZAJE SEMISUPERVISADO (0)			
APRENDIZAJE REFORZADO (7)			
Positivo		5	ID7, ID29, ID172, ID262, ID291
Múltiple		2	ID143, ID455
MONITOREO DE RED (41)			
APRENDIZAJE SUPERVISADO (40)			
CLASIFICACIÓN (33)	SVM	1	ID650
	Redes Neuronales	15	ID79, ID114, ID139, ID221, ID228, ID255, ID256, ID281, ID478, ID581, ID697, ID720, ID726, ID736, ID787
	Múltiple	14	ID59, ID158, ID163, ID166, ID189, ID209, ID267, ID457, ID519, ID638, ID733, ID740, ID765, ID814
	Otros	3	ID106, ID107, ID361
REGRESIÓN (7)	Regresión lineal	1	ID189
	Otros	6	ID207, ID473, ID519, ID650, ID670, ID695
APRENDIZAJE NO SUPERVISADO (1)			
AGRUPACIÓN (1)	Otros	1	ID608
REDUCCIÓN DE DIMENSIONALIDAD (0)			-----
APRENDIZAJE SEMISUPERVISADO (0)			
APRENDIZAJE REFORZADO (0)			
CLASIFICACIÓN Y PREDICCIÓN DEL TRÁFICO (16)			
APRENDIZAJE SUPERVISADO (13)			
CLASIFICACIÓN (12)	Redes Neuronales	6	ID43, ID72, ID139, ID151, ID172, ID174
	Naive Bayes	1	ID11
	Múltiple	3	ID306, ID498, ID706
	Otros	2	ID471, ID702
REGRESIÓN (1)	Otros	1	ID706
APRENDIZAJE NO SUPERVISADO (0)			
AGRUPACIÓN (0)			-----
REDUCCIÓN DE DIMENSIONALIDAD (0)			-----
APRENDIZAJE SEMISUPERVISADO (1)			
Otros		1	ID702
APRENDIZAJE REFORZADO (2)			
Positivo		2	ID172, ID533
GESTIÓN DE FALLAS (37)			
APRENDIZAJE SUPERVISADO (27)			
CLASIFICACIÓN (27)	SVM	5	ID69, ID156, ID452, ID574, ID816
	K-vecino más cercano	1	ID200
	Redes Neuronales	7	ID114, ID172, ID228, ID461, ID648, ID786, ID820
	Naive Bayes	3	ID36, ID67, ID677
	Múltiple	7	ID102, ID125, ID128, ID318, ID331, ID420, ID470
	Otros	4	ID16, ID66, ID109, ID716
REGRESIÓN (0)			-----
APRENDIZAJE NO SUPERVISADO (4)			
AGRUPACIÓN (3)	Otros	3	ID331, ID452, ID778
REDUCCIÓN DE DIMENSIONALIDAD (1)	Codificadores Automáticos	1	ID574
APRENDIZAJE SEMISUPERVISADO (5)			
Otros		5	ID66, ID102, ID109, ID125, ID452
APRENDIZAJE REFORZADO (1)			
Positivo		1	ID172