

Técnicas de Inteligencia Artificial para Detección de Fallas en Redes Móviles y Ópticas
Artificial Intelligence Techniques for Fault Detection in Mobile and Optical Networks

Gema Juliana Zambrano Loor & David Fernando Zambrano Montenegro

DIMENSIÓN CIENTÍFICA

Enero - junio, V°7 - N°1; 2026

Recibido: 07-05-2026

Aceptado: 08-05-2026

Publicado: 14-05-2026

PAIS

- Ecuador, Portoviejo
- Ecuador, Portoviejo

INSTITUCION

- Universidad Técnica de Manabí
- Universidad Técnica de Manabí

CORREO:

- ✉ gzambrano9138@utm.edu.ec
- ✉ devizamm@gmail.com

ORCID:

- 🌐 <https://orcid.org/0009-0005-1085-4047>
- 🌐 <https://orcid.org/0000-0002-8833-1546>

FORMATO DE CITA APA.

Zambrano, G. & Zambrano, D (2026). Técnicas de Inteligencia Artificial para Detección de Fallas en Redes Móviles y Ópticas. *Revista G-ner@ndo*, V°7 (N°1). Pág. 5103 – 5128.

Resumen

Las redes móviles y las redes ópticas constituyen la base de los servicios de telecomunicaciones modernos, por lo que la detección temprana de fallas es esencial para asegurar la continuidad operativa y la calidad de servicio. Los enfoques tradicionales de supervisión, apoyados en umbrales fijos y reglas estáticas, resultan insuficientes ante el crecimiento del tráfico y la complejidad de las arquitecturas. En este contexto, el objetivo de este trabajo es analizar de manera sistemática las técnicas de inteligencia artificial aplicadas a la detección de fallas y anomalías en redes móviles y ópticas. Se realizó una revisión sistemática (PRISMA 2020) de artículos publicados entre enero de 2020 y febrero de 2026 (búsqueda ejecutada en febrero de 2026) en Scopus e IEEE Xplore. Tras el proceso de selección, se incluyeron 21 estudios que aplican métodos de aprendizaje automático y aprendizaje profundo a tareas de detección, clasificación y localización de fallas en redes ópticas (OTDR: optical time-domain reflectometry; SOP: state of polarization; SOPAS: state of polarization angular speed; DDM: digital diagnostic monitoring) y en redes móviles y en el núcleo 5G (KPIs: key performance indicators; logs operativos). La literatura revisada sugiere una transición desde técnicas clásicas de aprendizaje automático (ML) hacia arquitecturas profundas (autoencoders, LSTM/BiLSTM, CNN, modelos híbridos y enfoques basados en grafos). En varios estudios se informan mejoras en métricas de detección (p. ej., precisión y reducción de falsas alarmas) y, en algunos casos, capacidad de localización. Entre las tendencias reportadas se incluyen modelos ligeros para despliegue y estrategias autosupervisadas y de aprendizaje activo. Persisten desafíos vinculados a escasez de datos reales etiquetados, generalización entre entornos y necesidad de explicabilidad en contextos operativos.

Palabras clave: detección de fallas; redes móviles; redes ópticas; inteligencia artificial; aprendizaje profundo.

Abstract

Mobile and optical networks constitute the backbone of modern telecommunications services; therefore, early fault detection is essential to ensure operational continuity and quality of service. Traditional monitoring approaches based on fixed thresholds and rule-based systems are increasingly insufficient in the face of traffic growth and architectural complexity. In this context, the aim of this work is to systematically analyze artificial intelligence techniques applied to fault and anomaly detection in mobile and optical networks. A systematic literature review was conducted following the PRISMA 2020 guidelines, considering articles published between January 2020 and February 2026; the search was conducted in February 2026. After the selection process, 21 primary studies were included. These works apply machine learning and deep learning methods to fault detection, classification, and localization tasks in optical networks (OTDR traces, SOP/SOPAS signatures, DDM measurements) and in mobile and 5G core networks (performance KPIs and operational logs). The reviewed literature shows a shift from classical ML techniques towards deep architectures (autoencoders, LSTM/BiLSTM, CNN, hybrid models, and graph-based approaches). Across studies, improvements are reported in detection metrics and false-alarm reduction, and in some cases in localization capability; however, results are not directly comparable due to differences in datasets and validation protocols. Emerging directions include lightweight models for deployment and self-supervised or active learning strategies, while key open issues remain related to scarce labeled operational data, cross-environment generalization, and explainability requirements.

Keywords: fault detection; mobile networks; optical networks; artificial intelligence; deep learning.

Introducción

Las redes de telecomunicaciones constituyen hoy la columna vertebral del desarrollo tecnológico, económico y social a escala global. Infraestructuras como las redes móviles y de fibra óptica sustentan servicios críticos que abarcan desde el acceso a internet y aplicaciones en la nube hasta la gestión del tráfico urbano y sectores estratégicos como la salud y la educación. En este contexto, garantizar la disponibilidad, la confiabilidad y la calidad de servicio de estas redes se ha convertido en una prioridad estratégica, ya que fallas aparentemente locales pueden traducirse en interrupciones masivas, pérdidas económicas significativas y afectaciones directas a la experiencia de usuario.

La creciente complejidad de las arquitecturas de red... ha evidenciado las limitaciones de los enfoques tradicionales de supervisión, los cuales dependen de reglas estáticas, umbrales prefijados o protocolos de análisis manual de alarmas. En redes ópticas, las fallas abarcan desde cortes de fibra y curvaturas excesivas hasta intrusiones físicas y degradaciones sutiles que solo se manifiestan en las trazas OTDR o en el estado de polarización de la señal (Abdelli et al., 2022; Malik et al., 2025b). En redes móviles y núcleos 5G, los incidentes se reflejan en desviaciones complejas de los indicadores de rendimiento, congestión en la RAN, anomalías en la gestión de movilidad o comportamientos anómalos en funciones virtualizadas del core (Ahasan et al., 2022; Hosseini et al., 2025; Issa et al., 2023).

Ante este escenario, la inteligencia artificial (IA), y en particular las técnicas de machine learning (ML) y deep learning (DL), se han posicionado como herramientas clave para la detección temprana de fallas, la identificación de patrones anómalos y el soporte al diagnóstico automatizado. En redes ópticas, diversos trabajos proponen modelos supervisados y profundos aplicados a trazas OTDR, medidas DDM o firmas de polarización

para detectar y localizar eventos de falla con alta precisión, incluso en presencia de ruido y condiciones ambientales variables (Abdelli et al., 2023; Malik et al., 2025b). De forma análoga, en redes móviles y en el núcleo 5G (5G core) se han explorado autoencoders, redes recurrentes y arquitecturas ligeras para detectar anomalías en KPIs y logs, así como para reducir el tiempo de análisis de causa raíz en entornos operativos reales (Ahasan et al., 2022; Issa et al., 2023; Vinh et al., 2024; Yuan et al., 2020).

A pesar de estos avances, el conocimiento disponible se encuentra fragmentado. Los estudios difieren en el tipo de red (PON, troncales ópticas, sistemas radio-sobre-fibra, RAN 4G/5G, núcleos 5G basados en VNFs), en las fuentes de datos empleadas (OTDR, SOP/SOPAS, DDM, KPIs, logs de señalización, métricas OSS/NPM), en las tareas específicas abordadas (detección, clasificación, localización de fallas, análisis de causa raíz) y en las métricas de evaluación reportadas. Esta heterogeneidad dificulta obtener una visión integrada sobre qué técnicas de IA se están utilizando, en qué contextos son más efectivas y cuáles son las principales limitaciones para su adopción en redes operativas a gran escala (Yuan et al., 2020; Zhu et al., 2024).

En este marco, el presente trabajo tiene como objetivo sistematizar y analizar críticamente la aplicación de técnicas de inteligencia artificial para la detección de fallas en redes móviles y redes ópticas, a partir de la evidencia reportada en la literatura reciente. Para ello, se llevó a cabo una revisión sistemática de literatura siguiendo las directrices del modelo PRISMA 2020, centrada en estudios publicados entre enero de 2020 y febrero de 2026 (búsqueda ejecutada en febrero de 2026) en bases de datos de alto impacto como Scopus e IEEE Xplore. Tras un proceso de identificación, cribado y evaluación de elegibilidad, se seleccionaron 21 artículos que cumplen criterios de rigor metodológico, reporte explícito de métricas de desempeño y foco directo en la detección y/o diagnóstico de fallas en redes ópticas o móviles mediante técnicas de IA.

Esta revisión se propone: (i) identificar los tipos de redes y escenarios en los que se han aplicado técnicas de IA para la detección de fallas; (ii) clasificar las técnicas de ML/DL empleadas y las tareas que abordan (detección, clasificación, localización, análisis de causa raíz); (iii) sintetizar los conjuntos de datos, métricas de evaluación y resultados cuantitativos reportados; y (iv) destacar los desafíos y tendencias emergentes en términos de generalización, disponibilidad de datos etiquetados, robustez frente al ruido, explicabilidad y despliegue en entornos productivos. De este modo, el artículo busca ofrecer una visión integrada del estado del arte y servir como base para el diseño de soluciones de detección inteligente de fallas más robustas y escalables en redes móviles y ópticas de próxima generación.

Métodos y Materiales

Diseño del estudio

Este estudio corresponde a una revisión sistemática de literatura (SLR) orientada a identificar, clasificar y sintetizar técnicas de inteligencia artificial aplicadas a la detección, diagnóstico, clasificación y localización de fallas y anomalías en redes móviles (4G/5G y núcleo 5G) y redes ópticas (fibra, PON y monitorización basada en OTDR/SOP/DDM). El protocolo metodológico se estructuró de acuerdo con PRISMA 2020, priorizando la reproducibilidad mediante la definición explícita de las fuentes y la estrategia de búsqueda, los criterios de elegibilidad, la trazabilidad del proceso de selección y el uso de una matriz de extracción para la síntesis comparativa.

El protocolo no fue preregistrado en repositorios públicos (p. ej., Open Science Framework [OSF]); sin embargo, la estrategia de búsqueda, los criterios de elegibilidad y el flujo PRISMA se documentaron y reportaron explícitamente para favorecer la reproducibilidad.

Fuentes de información y estrategia de búsqueda

La búsqueda bibliográfica se realizó en Scopus e IEEE Xplore Digital Library, debido a su cobertura en telecomunicaciones e ingeniería. De forma complementaria, se aplicó snowballing retrospectivo (backward snowballing) a partir de las listas de referencias de los estudios evaluados a texto completo y de los estudios finalmente incluidos, con el fin de identificar trabajos relevantes que podrían no haber sido recuperados por la cadena inicial (p. ej., variaciones terminológicas). Los registros identificados por búsqueda manual fueron verificados para cumplir los mismos criterios de elegibilidad, incluyendo el periodo definido, el tipo de publicación revisada por pares y su indexación en Scopus y/o IEEE Xplore.

Se incluyeron publicaciones entre enero de 2020 y febrero de 2026, y la búsqueda se ejecutó en febrero de 2026. Se consideraron artículos de revista y ponencias de congreso revisados por pares, escritos en inglés o español.

La estrategia de búsqueda combinó tres bloques conceptuales: problema (fault detection, fault diagnosis, fault localization, anomaly detection, root cause analysis), dominio (redes móviles: 4G/LTE/5G, RAN, 5G core; y redes ópticas: optical network, fiber/fibre, PON, OTDR, SOP/SOPAS, DDM) y técnicas (artificial intelligence, machine learning, deep learning, y familias de modelos como autoencoders, LSTM, CNN, transformers y GNN). En Scopus se consultaron título, resumen y palabras clave (TITLE-ABS-KEY), mientras que en IEEE Xplore se empleó una búsqueda conceptualmente equivalente en modo Full Text, aplicando filtros por periodo (2020–febrero 2026), tipo de publicación (journals y conferences) e idioma (inglés/español). Las cadenas utilizadas se reportan a continuación de forma literal para permitir su replicación.

Scopus (TITLE-ABS-KEY):

TITLE-ABS-KEY(("fault detection" OR "fault diagnosis" OR "fault localization" OR "anomaly detection" OR "root cause analysis" OR "failure detection") AND ("mobile network" OR "cellular network" OR "wireless network" OR "4G" OR "LTE" OR "5G" OR "5G core" OR "RAN" OR "optical network" OR "fiber optic" OR "fibre optic" OR "passive optical network" OR "PON" OR "OTDR" OR "optical time-domain reflectometry" OR "state of polarization" OR "SOP" OR "SOPAS" OR "digital diagnostic monitoring" OR "DDM") AND ("artificial intelligence" OR "machine learning" OR "deep learning" OR "neural network" OR "autoencoder" OR "LSTM" OR "CNN" OR "transformer" OR "graph neural network" OR "GNN"))

IEEE Xplore (Full Text):

("fault detection" OR "fault diagnosis" OR "fault localization" OR "anomaly detection" OR "root cause analysis") AND ("5G" OR "5G core" OR "LTE" OR "4G" OR "RAN" OR "mobile network" OR "cellular network" OR "optical network" OR "fiber optic" OR "fibre optic" OR "PON" OR "OTDR" OR "SOP" OR "SOPAS" OR "DDM") AND ("artificial intelligence" OR "machine learning" OR "deep learning" OR "neural network" OR "autoencoder" OR "LSTM" OR "CNN" OR "transformer" OR "graph neural network")

En IEEE Xplore se aplicaron filtros por periodo (2020–febrero 2026), tipo de publicación (journals y conferences) e idioma (inglés/español) para homogeneizar el conjunto recuperado. Los documentos no relacionados directamente con detección o diagnóstico de fallas en infraestructura de redes móviles u ópticas (p. ej., IDS genéricos o análisis de fraude sin vínculo operacional con fallas) se descartaron de acuerdo con los criterios de exclusión definidos.

En Scopus, además del rango temporal, se restringieron los resultados a artículos de revista y ponencias de congreso, en inglés o español, para mantener consistencia con los filtros aplicados en IEEE Xplore.

Gestión de registros y eliminación de duplicados

Los registros recuperados desde Scopus e IEEE Xplore fueron exportados y gestionados en Mendeley. La eliminación de duplicados se realizó mediante coincidencia de DOI y, cuando este no estuvo disponible, por coincidencia de título, autores y año. Cuando Mendeley no resolvió de forma inequívoca la duplicación (p. ej., títulos muy similares sin DOI), se efectuó verificación manual para evitar falsos duplicados o pérdida de registros relevantes. El conjunto consolidado se utilizó para el cribado por título y resumen y para la evaluación de elegibilidad a texto completo.

Criterios de inclusión y exclusión

Se incluyeron estudios que cumplieron simultáneamente las siguientes condiciones: aplicar explícitamente técnicas de inteligencia artificial (por ejemplo, aprendizaje supervisado o no supervisado, deep learning, modelos basados en grafos, aprendizaje federado, transformers, esquemas híbridos o autosupervisados); abordar como objetivo principal la detección, diagnóstico, localización o predicción de fallas y anomalías en redes móviles (4G, 5G, RAN, núcleo 5G, funciones virtualizadas) y/o redes ópticas (fibra, PON, radio-sobre-fibra y monitorización mediante OTDR/SOP/DDM); reportar validación experimental o por simulación con métricas cuantitativas (p. ej., accuracy, precision, recall, F1-score, AUC, RMSE, latencia de inferencia); y estar indexados en Scopus y/o IEEE Xplore dentro del periodo temporal definido. Cuando un mismo enfoque apareció en más de una publicación (p. ej., congreso y extensión en revista), se conservó la versión más completa y/o la publicada en revista como evidencia principal.

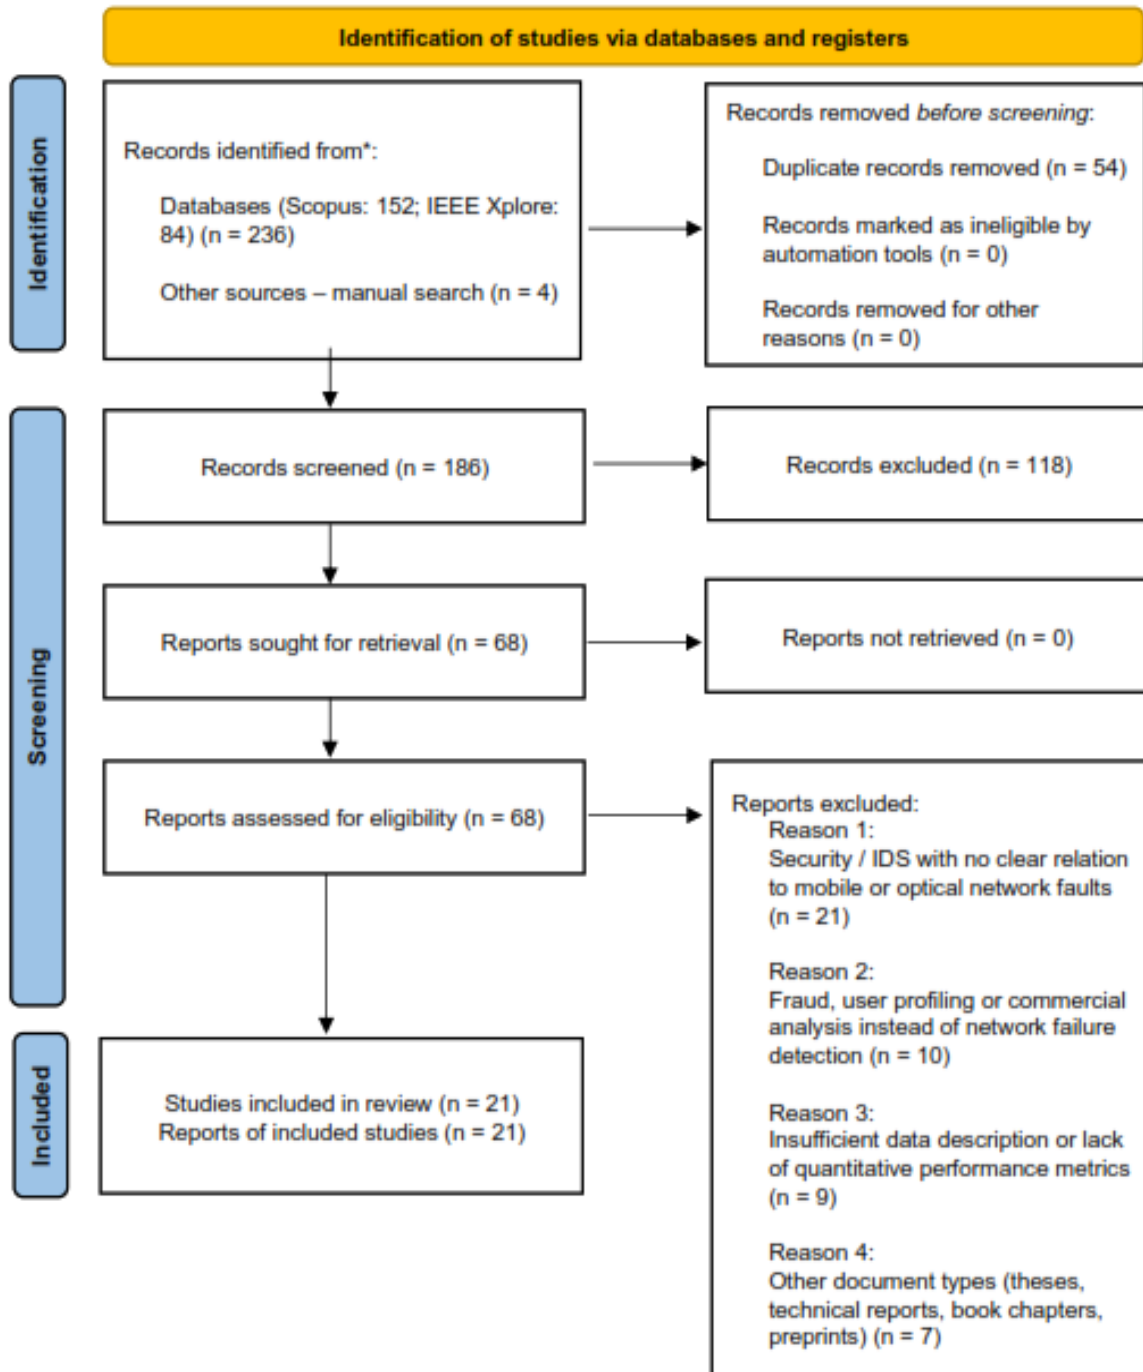
Se excluyeron estudios centrados exclusivamente en seguridad informática o detección de intrusiones genéricas (IDS/IPS sobre tráfico IP, MANET o IoT) sin relación clara con fallas de infraestructura u operación de red; investigaciones enfocadas principalmente en fraude, perfilamiento de usuarios, facturación o análisis comercial; documentos no revisados por pares (tesis, capítulos de libro, informes técnicos, preprints); trabajos sin descripción suficiente del conjunto de datos o sin reporte de métricas cuantitativas; y duplicados residuales detectados durante el cribado.

Proceso de selección de estudios

La selección siguió las fases PRISMA: identificación, cribado, elegibilidad e inclusión. Se identificaron 240 registros (Scopus: 152; IEEE Xplore: 84; búsqueda manual: 4). Tras depurar 54 duplicados, se cribaron 186 registros por título y resumen, excluyéndose 118 por no alinearse con el objetivo de la revisión. Posteriormente, se evaluaron 68 textos completos y se excluyeron 47 por criterios predefinidos: enfoque en seguridad/IDS sin relación clara con fallas en redes móviles u ópticas ($n = 21$), fraude o análisis comercial ($n = 10$), ausencia de métricas cuantitativas o reporte insuficiente del desempeño ($n = 9$), y tipo documental no elegible ($n = 7$). El corpus final quedó conformado por 21 estudios primarios.

El cribado por título/resumen y la evaluación de elegibilidad a texto completo fueron realizados de forma independiente por ambos autores. Las discrepancias se resolvieron mediante consenso en revisión conjunta; cuando fue necesario, se reexaminó el registro o el texto completo hasta alcanzar acuerdo. Los motivos de exclusión a texto completo se registraron en la matriz de extracción, consignando un motivo principal por estudio para asegurar trazabilidad. El flujo completo del proceso se presenta en la Figura 1.

Figura 1. Diagrama de flujo PRISMA del proceso de selección de estudios.



Evaluación de calidad metodológica

Para valorar la consistencia del reporte y la solidez metodológica de los estudios incluidos, se aplicó una lista de verificación breve adaptada a revisiones en ingeniería, considerando: claridad del objetivo y del escenario de red, descripción suficiente del conjunto de datos (origen, tamaño y variables), definición explícita de la tarea (detección/clasificación/localización/análisis de causa raíz [RCA]) y del protocolo experimental, reporte de métricas cuantitativas y configuración de validación, comparación con línea base o método de referencia y declaración de limitaciones. Cada ítem se calificó como sí/no/parcial. Esta verificación se empleó como apoyo para interpretar críticamente la evidencia durante la síntesis narrativa y comparativa, sin excluir estudios adicionales más allá de los criterios PRISMA.

Extracción y síntesis de la información

Para cada uno de los 21 estudios incluidos se realizó extracción sistemática mediante una matriz diseñada ad hoc e implementada en una hoja de cálculo para facilitar la trazabilidad y el control de versiones. La matriz se pilotó inicialmente en un subconjunto de estudios para ajustar campos y criterios de registro. La extracción fue realizada por ambos autores y posteriormente contrastada; las discrepancias se resolvieron por consenso.

En la matriz se registraron, como mínimo, la referencia bibliográfica; el tipo de red y escenario tecnológico (p. ej., troncal/acceso, PON, OTDR/SOP/DDM, 4G/5G RAN, núcleo 5G, funciones de red virtualizadas [VNFs]); el tipo de problema abordado (detección, diagnóstico, clasificación, localización, predicción temprana, RCA, multievento); el tipo de datos utilizados (OTDR, SOP/SOPAS, DDM, KPIs, logs, etc.); las técnicas de IA aplicadas (ML clásico, DL, grafos, autosupervisado, federado, por transferencia, híbridos); el tipo de

aprendizaje; el origen del conjunto de datos (simulación, laboratorio, red operativa o conjunto de datos público); las métricas reportadas (p. ej., accuracy, precision, recall, F1-score, AUC, RMSE, latencia); y los principales hallazgos, ventajas y limitaciones reportadas por los autores.

La información recopilada se organizó en tablas comparativas diferenciando redes ópticas y redes móviles, lo que permitió identificar técnicas predominantes por entorno, analizar el grado de madurez y validación de las propuestas (simulación, laboratorio, red real) y resaltar vacíos de investigación, desafíos técnicos y oportunidades de mejora para el diseño de soluciones de detección inteligente de fallas en redes de telecomunicaciones.

Análisis de resultados

Resultados en redes ópticas

Los estudios centrados en redes ópticas se agrupan en tres escenarios principales: monitorización basada en trazas OTDR, análisis del estado de polarización (SOP) y diagnóstico de módulos o elementos específicos de la cadena óptica. En el conjunto revisado se observa el uso de enfoques basados en aprendizaje automático supervisado, así como propuestas más recientes apoyadas en arquitecturas de aprendizaje profundo y modelos basados en grafos, en función del tipo de señal, la disponibilidad de datos y la tarea abordada (Abdelli et al., 2022; Abdelli et al., 2023; Asok & Pournami, 2023; Li et al., 2024; Malik et al., 2025b; Nakamura & Higashino, 2025; Sadighi et al., 2026).

En el subconjunto de trabajos que utilizan trazas OTDR, predominan modelos supervisados de clasificación y/o regresión, incluyendo árboles de decisión, Random Forest, SVM, k-NN y métodos de boosting, entrenados para identificar eventos de falla y, en varios casos, estimar su localización. De acuerdo con los estudios revisados, estos

enfoques reportan mejoras en métricas de desempeño frente a esquemas basados exclusivamente en reglas o umbrales, especialmente cuando incorporan extracción y selección de características orientadas al evento, junto con modelos de mayor capacidad de representación (Abdelli et al., 2022; Abdelli et al., 2023; Asok & Pournami, 2023; Battal et al., 2023; Lakshmi & Brindha, 2024; Patel et al., 2024). No obstante, la comparación directa entre trabajos resulta limitada por diferencias en el origen de los datos (laboratorio, campo u operador), condiciones de ruido, definición de clases de falla y protocolos de validación.

Un segundo grupo de estudios emplea el estado de polarización (SOP) y su derivada (SOPAS) para caracterizar perturbaciones físicas y escenarios multievento. En este caso, se reporta el uso de clasificadores supervisados (p. ej., Random Forest, XGBoost) para discriminar eventos como golpes, desplazamientos o vibraciones sobre la fibra. Los resultados informados muestran niveles de desempeño competitivos con costos computacionales moderados, condicionados por la estabilidad de las características derivadas de SOP/SOPAS y por la variabilidad del entorno de medición (Malik et al., 2025b; Sadighi et al., 2026).

En trabajos recientes se incorporan modelos profundos y representaciones estructuradas. Se reportan propuestas basadas en autoencoders (convolucionales o recurrentes) para detección de anomalías, así como métodos basados en grafos aplicados a módulos ópticos o topologías donde la conectividad aporta información adicional para el diagnóstico. Estos enfoques se presentan como alternativas para capturar dependencias temporales y/o estructurales que no se reflejan plenamente en clasificadores convencionales (Abdelli et al., 2022; Li et al., 2024; Malik et al., 2025a; Malik et al., 2025b; Nakamura & Higashino, 2025). Asimismo, se describen estrategias autosupervisadas o con

baja disponibilidad de muestras de falla para reducir la dependencia de etiquetas, aunque los escenarios y condiciones de evaluación siguen siendo heterogéneos entre estudios.

En síntesis, la literatura revisada informa mejoras en detección y, en algunos casos, en localización de fallas en redes ópticas, con resultados particularmente relevantes cuando se emplean datos de campo o mediciones representativas de condiciones reales. Sin embargo, una parte importante de las propuestas continúa validándose en entornos controlados, por lo que persisten desafíos asociados a la generalización entre distintos tipos de fibra, configuraciones de red y condiciones ambientales. La Tabla 1 presenta un subconjunto representativo de trabajos ópticos; la comparación transversal de patrones y tendencias se presenta en la sección Discusión (Tabla 3).

Tabla 1. *Estudios sobre detección de fallas y anomalías en redes ópticas mediante inteligencia artificial.*

| Autor(es) y año | Tipo de red / entorno | Técnicas de IA | Tarea principal | Datos y resultados clave |
|------------------------|--|--|---|--|
| Abdelli et al., 2022 | Red óptica troncal monitorizada con OTDR | Autoencoder (GRU-AE) + BiGRU con atención | Detección de anomalías y diagnóstico/localización de eventos | Trazas OTDR reales con distintos niveles de ruido. Se detectan y localizan cortes, curvaturas y empalmes defectuosos con $F1 \approx 0,96$ y precisión de diagnóstico $> 95 \%$, con error de localización del orden de decímetros. |
| Abdelli et al., 2023 | Red PON de acceso | Clasificadores supervisados (árboles, SVM, etc.) | Clasificación automática de eventos OTDR en enlaces PON | Trazas OTDR capturadas en planta real. El modelo distingue varios tipos de fallas en tiempo casi real y reduce de forma importante las falsas alarmas frente a umbrales fijos. |
| Asok y Pournami, 2023 | Red de fibra óptica subterránea | Modelos de regresión supervisada sobre parámetros OTDR | Estimación precisa de la localización física de fallas en cables subterráneos | Medidas OTDR de laboratorio y campo. Se obtiene un error medio de localización bajo, adecuado para apoyar |

| | | | | |
|-------------------------|--|--|--|---|
| Battal et al., 2023 | Líneas de Internet sobre fibra de un ISP | Enfoque híbrido: <i>clustering</i> + clasificación supervisada | Detección temprana de degradaciones en líneas de fibra | tareas de mantenimiento y excavación dirigida. Datos operativos de potencia, atenuación y errores. El modelo diferencia entre líneas sanas y líneas en riesgo, habilitando mantenimiento preventivo más eficiente que reglas estáticas. |
| Patel et al., 2024 | Fibras que interconectan sistemas de videovigilancia y tráfico | LightGBM, XGBoost, CatBoost, AdaBoost | Clasificación de tipos de falla a partir de trazas OTDR | Trazas OTDR con SNR y potencias P1–P30. LightGBM y XGBoost obtienen las mejores tasas de acierto y tiempos de entrenamiento, adecuados para monitorización casi en tiempo real. |
| Lakshmi y Brindha, 2024 | Redes ópticas afectadas por condiciones ambientales | Modelos supervisados (p. ej., Random Forest, SVM) | Diferenciar efectos ambientales de fallas reales | Dataset que combina OTDR y sensores de entorno (temperatura, humedad, vibraciones). Se reduce significativamente la cantidad de falsas alarmas en comparación con detectores que solo analizan la traza óptica. |
| Li et al., 2024 | Módulos de fibra óptica en red de operador (DDM) | Graph Autoencoder (GAE) no supervisado | Detección de módulos ópticos anómalos | Datos DDM reales modelados como grafo (nodos = módulos, aristas = enlaces). El GAE mejora la precisión y la exhaustividad en la detección de módulos problemáticos al explotar la estructura de red. |
| Malik et al., 2025b | Enlaces de fibra monitorizados mediante SOP/SOPAS | Random Forest, SVM, Regresión logística, XGBoost | Detección y clasificación de múltiples eventos mecánicos en la fibra | Firmas experimentales de polarización (golpes pequeños, desplazamientos, sacudidas). Random Forest y XGBoost logran alta precisión con buen compromiso entre exactitud y coste computacional. |
| Malik et al., 2025a | Redes ópticas con anomalías solapadas | XGBoost sobre características | Detección de anomalías | Datos simulados/experimentales. El modelo identifica con |

| | | | | |
|----------------------------|---|---|--|--|
| | | de SOP/SOPAS | superpuestas (varios eventos simultáneos) | alta precisión combinaciones de eventos (p. ej., curvatura + golpe), mejorando la visibilidad de situaciones complejas en la fibra. |
| Nakamura & Higashino, 2025 | Sistema radio-sobre-fibra (RoF) MIMO analógico | Clasificadores de <i>machine learning</i> | Detección de fallas y degradaciones en enlaces RoF | Medidas experimentales en un banco de pruebas RoF. Se automatiza la identificación de estados degradados y se mejora el diagnóstico respecto a umbrales físicos convencionales. |
| Sadighi et al., 2026 | Enlaces de fibra usados como sensor de seguridad física | Modelos de ML basados en análisis del SOP | Detección de amenazas emergentes y manipulaciones sobre la fibra | Datos de monitorización continua del estado de polarización. Los modelos alcanzan altos valores de F-score y permiten discriminar patrones sutiles asociados a ataques o perturbaciones no deseadas. |

Nota. OTDR = optical time-domain reflectometry; PON = passive optical network; SOP = state of polarization; SOPAS = velocidad angular del estado de polarización; DDM = digital diagnostic monitoring; ISP = proveedor de servicios de Internet; ML = machine learning

Resultados en redes móviles y 5G

En redes móviles, los estudios incluidos se concentran en tres frentes: detección de anomalías en KPIs en redes 4G/5G, diagnóstico de fallas en el núcleo 5G y análisis de causa raíz apoyado en múltiples fuentes de telemetría, incluyendo KPIs, métricas OSS/NPM, logs y trazas operativas (Ahasan et al., 2022; Hosseini et al., 2025; Issa et al., 2023; Johari et al., 2026; Vinh et al., 2024; Yuan et al., 2020; Zhu et al., 2024). En términos generales, las propuestas trabajan con series temporales y registros operativos de distinta granularidad, lo que condiciona el tipo de modelo y la estrategia de validación reportada en cada estudio.

Los trabajos basados en KPIs de redes 4G suelen emplear autoencoders y modelos recurrentes para aprender patrones de comportamiento normal y detectar desviaciones. Los estudios revisados reportan reducciones de falsos positivos respecto a umbrales estáticos y mejoras en la detección de degradaciones graduales; no obstante, el desempeño se encuentra fuertemente influido por decisiones de preprocesamiento, selección de KPIs, tamaño de ventana temporal y criterio de umbralización (Ahasan et al., 2022; Hosseini et al., 2025).

En el núcleo 5G y en funciones de red virtualizadas, se reporta el uso de CNN, LSTM/BiLSTM y arquitecturas híbridas CNN–LSTM, a partir de KPIs, trazas de señalización y logs, con el objetivo de diagnosticar fallas en componentes específicos. En estudios recientes se incorporan transformers para series temporales y aprendizaje activo para reducir el esfuerzo de etiquetado, particularmente en escenarios con escasez de fallas registradas (Issa et al., 2023; Johari et al., 2026; Vinh et al., 2024; Zhu et al., 2024). Aun así, las diferencias entre datasets, definición de fallas y esquemas de validación limitan comparaciones cuantitativas directas.

Otro conjunto de propuestas describe arquitecturas integrales que combinan múltiples fuentes (KPIs, logs y telemetría de infraestructura virtualizada) e incluyen módulos para priorización de alarmas o para apoyar el análisis de causa raíz. En estos estudios se reportan esfuerzos por reducir latencia y carga computacional, orientados a condiciones operacionales de despliegue (Johari et al., 2026; Yuan et al., 2020). La Tabla 2 sintetiza un subconjunto representativo de estudios en redes móviles/5G; la comparación transversal de patrones y tendencias se presenta en la sección Discusión (Tabla 3).

Tabla 2. Estudios sobre detección de fallas y anomalías en redes móviles mediante inteligencia artificial.

| Autor(es) y año | Tipo de red / entorno | Técnicas de IA | Tarea principal | Datos y resultados clave |
|-----------------------|---|--|---|---|
| Ahasan et al., 2022 | Red 4G comercial (rendimiento de red) | Autoencoder de deep learning | Detección de anomalías en KPIs de rendimiento de red 4G | KPIs de red obtenidos de un OSS de operador. El autoencoder aprende el comportamiento normal y detecta desviaciones; se analiza el efecto del número de capas y umbrales, logrando mejor desempeño que reglas basadas en umbrales estáticos. |
| Hosseini et al., 2025 | Red móvil multitecnología (datos Nokia NPM) | Isolation Forest | Detección de anomalías en problemas de rendimiento de red | Datos reales de rendimiento de Nokia Network Performance Manager. Isolation Forest permite identificar incidencias en KPIs de forma automatizada, con buena interpretabilidad para soportar operación y mantenimiento. |
| Yuan et al., 2020 | Red móvil multitecnología (RAN y core) | Pipeline de DL para AD + módulo de RCA | Detección de anomalías y análisis de causa raíz habilitado por IA | KPIs, logs y métricas de redes celulares a gran escala. El framework integra preprocesamiento, detección de anomalías mediante deep learning y un módulo específico de análisis de causa raíz, reduciendo el tiempo de diagnóstico frente a procedimientos manuales. |
| Issa et al., 2023 | Núcleo 5G (gestión de movilidad) | Red neuronal profunda con BiLSTM | Detección de anomalías en la gestión de movilidad del core 5G | Trazas de tráfico y KPIs del núcleo 5G. El modelo BiLSTM captura dependencias temporales de largo plazo y mejora la detección de patrones anómalos frente a modelos clásicos más simples. |
| Zhu et al., 2024 | Núcleo 5G basado en VNFs | Aprendizaje por transferencia híbrido | Diagnóstico de fallas en funciones virtualizadas del core 5G | Logs y KPIs de VNFs del núcleo 5G en distintos entornos. El enfoque de transferencia híbrida reutiliza conocimiento de un dominio fuente y lo adapta a un dominio destino con pocos datos de falla, elevando la capacidad de diagnóstico en configuraciones cambiantes. |

| | | | | |
|---------------------|---|---|---|---|
| Vinh et al., 2024 | Núcleo 5G de operador | Modelo ligero de DL para AD | Detección de anomalías en el core 5G con baja carga computacional | Métricas operativas de un núcleo 5G. El modelo se diseña para ofrecer buena precisión con bajo consumo de recursos, facilitando su despliegue en entornos productivos con restricciones de latencia. |
| Johari et al., 2026 | Redes 5G y beyond (series temporales de KPIs) | Transformer para series temporales + aprendizaje activo | Diagnóstico de fallas con etiquetado reducido | Series temporales de KPIs y métricas de red. El modelo Transformer se combina con aprendizaje activo para seleccionar muestras informativas, reduciendo el esfuerzo de etiquetado y manteniendo alta precisión en el diagnóstico de fallas. |

Nota. AL = active learning; AD = anomaly detection; RCA = root cause analysis; KPIs = indicadores clave de desempeño; OSS = operations support system; VNFs = funciones de red virtualizadas.

Discusión

La evidencia sintetizada en esta revisión sugiere que la aplicación de técnicas de inteligencia artificial para detección y diagnóstico de fallas en redes ópticas y móviles/5G responde a presiones comunes de operación: mayor complejidad arquitectónica, heterogeneidad tecnológica y crecimiento de la telemetría disponible. En esta sección se interpretan patrones transversales y diferencias de madurez entre dominios, con énfasis en disponibilidad de datos reales, generalización entre entornos y criterios de evaluación orientados a operación. Para facilitar esta lectura comparativa, la Tabla 3 organiza las dimensiones clave (fuentes de datos, tareas, familias de modelos, métricas, retos y tendencias) y sirve como marco de síntesis para la discusión.

Tabla 3. Síntesis comparativa de técnicas de IA y tendencias en redes ópticas y móviles/5G

| Dimensión | Redes ópticas | Redes móviles y núcleo 5G | Síntesis transversal (tendencia observada) |
|-----------------------------------|---|--|---|
| Dominio de aplicación | Enlaces troncales, PON, sistemas RoF, sensores de seguridad basados en fibra | RAN 4G/5G, núcleo 5G, funciones virtualizadas, redes multitecnología | Aplicación de IA a múltiples segmentos de la red (acceso–transporte–core), con énfasis en soporte a operación y mantenimiento |
| Fuente principal de datos | Trazas OTDR, firmas SOP/SOPAS, medidas DDM, señales de laboratorio o banco de pruebas | KPIs de rendimiento, logs de eventos, trazas de señalización, métricas OSS/NPM | Integración progresiva de fuentes heterogéneas (sensado físico + telemetría de red) para mejorar visibilidad operativa |
| Tareas predominantes | Detección y localización de fallas físicas (cortes, curvaturas, intrusiones), diferenciación de ruido ambiental | Detección de anomalías en KPIs, diagnóstico de fallas, análisis de causa raíz, predicción de incidencias | Evolución desde detección aislada hacia flujos más completos de diagnóstico y soporte a la decisión |
| Técnicas de ML clásico | Árboles de decisión, Random Forest, SVM, k-NN, boosting aplicados a OTDR/DDM | Árboles, Random Forest, SVM, OCSVM, modelos ligeros para entornos operativos | El ML clásico se mantiene como base cuando se prioriza interpretabilidad, bajo costo y facilidad de despliegue |
| Técnicas de DL predominantes | Autoencoders (convolucionales/recurrentes), modelos híbridos para OTDR y SOP | Autoencoders, LSTM/BiLSTM, CNN, modelos híbridos CNN–LSTM para KPIs y logs | Uso creciente de DL para capturar patrones temporales y no lineales en señales y series operativas |
| Modelos avanzados y estructurales | Graph Autoencoder y enfoques que explotan topología óptica y relaciones entre módulos | Transformers para series temporales, aprendizaje activo, esquemas híbridos para núcleo 5G | Mayor presencia de modelos que incorporan estructura (topología/relaciones) y/o reducen dependencia de etiquetado masivo |
| Métricas de evaluación | Accuracy, F1, AUC, error de localización, robustez al ruido | Accuracy, F1, AUC, tasas de falsos positivos/negativos, | Se incorporan métricas operativas (latencia, robustez, localización, impacto en QoS) |

| | | | |
|-----------------------|---|---|--|
| Retos principales | Generalización a distintas fibras y condiciones ambientales, conjuntos de datos etiquetados limitados | tiempo de diagnóstico Escasez de datos de falla, cambios de configuración, heterogeneidad entre operadores | además de métricas clásicas Brecha reportada entre resultados de laboratorio/simulación y despliegue estable en redes comerciales |
| Tendencias emergentes | Sensado distribuido inteligente, combinación de OTDR/SOP con IA, detección de eventos multifalla | Núcleos 5G autogestionados, pipelines de IA para RCA, modelos ligeros desplegables en producción | Convergencia hacia soluciones de autogestión (self-healing), con énfasis creciente en explicabilidad y despliegue práctico |

Nota. IA = inteligencia artificial; PON = passive optical network; RoF = radio-over-fiber; OTDR = optical time-domain reflectometry; SOP = state of polarization; SOPAS = velocidad angular del estado de polarización; DDM = digital diagnostic monitoring; RAN = radio access network; KPIs = indicadores clave de desempeño; OSS = operations support system; NPM = network performance management; OCSVM = one-class support vector machine; QoS = calidad de servicio.

Evolución de enfoques y condicionantes operacionales.

En ambos dominios se observa un desplazamiento desde técnicas de ML clásico (p. ej., árboles, Random Forest, SVM, boosting) hacia arquitecturas profundas (autoencoders, LSTM/BiLSTM, CNN y esquemas híbridos), particularmente cuando los datos son secuenciales, ruidosos o de alta dimensionalidad. Este patrón es consistente con la necesidad de capturar dependencias temporales y relaciones no lineales presentes tanto en KPIs/logs (móviles/5G) como en firmas OTDR o variables derivadas de SOP/SOPAS (ópticas). Sin embargo, la evidencia revisada no permite afirmar una superioridad universal del DL: varios estudios mantienen modelos clásicos por interpretabilidad, menor costo computacional o restricciones de despliegue (latencia/recursos), por lo que la elección del enfoque suele reflejar un equilibrio entre capacidad de representación y viabilidad operativa (Abdelli et al., 2022; Ahasan et al., 2022; Issa et al., 2023; Patel et al., 2024; Zhu et al., 2024).

Datos, etiquetado y generalización como limitación estructural.

Un hallazgo transversal es la dependencia de datos representativos y, especialmente, de fallas etiquetadas, lo cual limita tanto la comparabilidad entre propuestas como su transferencia a producción. En redes ópticas, una parte de la evidencia proviene de escenarios controlados o bancos de prueba, mientras que en redes móviles/5G la variabilidad entre operadores, configuraciones y perfiles de tráfico incrementa el riesgo de deriva (“drift”) del comportamiento normal. En este contexto, se reporta interés creciente por enfoques que mitiguen la necesidad de etiquetas (aprendizaje autosupervisado, aprendizaje activo y transferencia), especialmente útiles en clases raras o fallas poco frecuentes; no obstante, la heterogeneidad de definiciones de falla, fuentes de datos y esquemas de validación sugiere que estas líneas deben interpretarse como tendencias emergentes más que como evidencia concluyente en todos los entornos (Johari et al., 2026; Malik et al., 2025a; Malik et al., 2025b; Zhu et al., 2024).

Modelos conscientes de topología y requisitos de implementación.

La Tabla 3 evidencia la incorporación de enfoques que explotan explícitamente estructura de red (principalmente modelos basados en grafos), tanto en diagnóstico de módulos ópticos como en escenarios donde la topología aporta contexto para inferencia y localización. Conceptualmente, estos enfoques son relevantes porque permiten pasar de decisiones basadas únicamente en valores puntuales de KPIs/señales a decisiones contextualizadas por conectividad y relaciones espaciales. Sin embargo, su adopción en entornos reales depende de la disponibilidad, calidad y actualización de la información topológica, así como de una sincronización robusta entre telemetría y estructura; por ello, su despliegue sostenido exige considerar gobernanza de datos, mantenimiento de grafos y

tolerancia a cambios de configuración (Johari et al., 2026; Li et al., 2024; Sadighi et al., 2026; Yuan et al., 2020).

Métricas operacionales y brecha entre laboratorio y producción.

Aunque predominan métricas clásicas (accuracy, precision, recall, F1-score, AUC), varios trabajos incorporan indicadores más cercanos a operación (latencia, robustez al ruido, error de localización y, en algunos casos, variables relacionadas con impacto en QoS). Este cambio es metodológicamente relevante, ya que en operación el costo de falsas alarmas, el tiempo de diagnóstico y la localización del evento pueden ser tan críticos como la exactitud. Aun así, la evidencia revisada sugiere una brecha persistente entre validaciones en laboratorio o simulación y despliegues sostenidos en redes comerciales, asociada a heterogeneidad de entornos, variabilidad temporal y restricciones de recursos, lo cual refuerza la necesidad de evaluaciones más alineadas con escenarios reales (Hosseini et al., 2025; Lakshmi & Brindha, 2024; Vinh et al., 2024).

Limitaciones y líneas futuras.

En conjunto, los resultados y patrones discutidos sugieren que el avance del campo dependerá menos de mejoras marginales de exactitud y más de resolver condiciones habilitantes: datos de referencia comparables, protocolos de validación consistentes, robustez frente a deriva y trazabilidad de las decisiones para adopción operativa. En este sentido, se prioriza: el desarrollo de conjuntos de datos y definiciones de falla más estandarizadas; la exploración de aprendizaje autosupervisado, por transferencia y federado para reducir dependencia de etiquetado; y la integración de modelos en plataformas de gestión/orquestación con capacidades de autogestión y autorreparación (self-healing), acompañadas de métricas operacionales y mecanismos de explicabilidad acordes al uso en operación.

Conclusiones

La revisión sistemática realizada (PRISMA 2020) sobre estudios publicados entre enero de 2020 y febrero de 2026 permitió sintetizar evidencia reciente sobre técnicas de inteligencia artificial aplicadas a detección y diagnóstico de fallas en redes ópticas y móviles/5G. En conjunto, la literatura revisada muestra una adopción creciente de enfoques basados en aprendizaje automático y aprendizaje profundo para analizar señales y telemetría de red (p. ej., OTDR, SOP/SOPAS, DDM, KPIs y logs), con el objetivo de apoyar la detección de anomalías y, en ciertos casos, contribuir a la localización o al diagnóstico de causa raíz.

En redes ópticas, los estudios reportan resultados favorables al emplear modelos supervisados sobre trazas OTDR y características derivadas de SOP/SOPAS, así como enfoques más recientes basados en autoencoders y modelos de grafos para escenarios con mayor complejidad, ruido o relaciones estructurales entre módulos. En redes móviles y núcleos 5G, se observa el uso recurrente de autoencoders, arquitecturas recurrentes (LSTM/BiLSTM) y modelos híbridos, orientados a series temporales de KPIs y registros operativos; adicionalmente, propuestas recientes incorporan estrategias como transferencia, transformers y aprendizaje activo para abordar cambios de configuración y limitaciones de etiquetado.

De forma transversal, la evidencia disponible sugiere que los principales desafíos para la adopción operativa no se limitan al desempeño predictivo, sino a condiciones habilitantes: disponibilidad de datos reales y etiquetados, comparabilidad entre protocolos de evaluación, generalización entre entornos heterogéneos y necesidad de trazabilidad/explicabilidad en procesos de operación y mantenimiento. Asimismo, persiste una brecha entre validaciones en laboratorio o simulación y despliegues sostenidos en

redes comerciales, donde el costo de falsas alarmas, la latencia, la robustez y la capacidad de localización resultan determinantes.

A partir de estos hallazgos, se plantea como agenda prioritaria avanzar hacia conjuntos de datos y definiciones de falla más consistentes, con protocolos de validación comparables y métricas alineadas con operación. En paralelo, se identifican como líneas prometedoras los esquemas autosupervisados, por transferencia y federados, así como modelos que incorporen estructura de red (p. ej., grafos), especialmente si se diseñan con restricciones de despliegue (latencia/recursos) y mecanismos de explicabilidad. Finalmente, integrar estas capacidades en plataformas de gestión y orquestación con funciones de autogestión y autorreparación (self-healing) aparece como el paso necesario para traducir avances académicos en valor operativo en redes de próxima generación.

Referencias bibliográficas

- Abdelli, K., Cho, J. Y., Azendorf, F., Griesser, H., Tropschug, C., & Pachnicke, S. (2022). Machine-learning-based anomaly detection in optical fiber monitoring. *Journal of Optical Communications and Networking*, 14(5), 365–375. <https://doi.org/10.1364/JOCN.451289>
- Abdelli, K., Tropschug, C., Griesser, H., & Pachnicke, S. (2023). Fault Monitoring in Passive Optical Networks using Machine Learning Techniques. *International Conference on Transparent Optical Networks*, 2023-July. <https://doi.org/10.1109/ICTON59386.2023.10207489>
- Ahasan, M. R., Haque, M. S., Akram, M. R., Momen, M. F., & Alam, M. G. R. (2022). Deep Learning Autoencoder based Anomaly Detection Model on 4G Network Performance Data. *2022 IEEE World AI IoT Congress, AllIoT 2022*, 232–237. <https://doi.org/10.1109/AllIoT54504.2022.9817338>
- Asok, A., & Pournami, S. S. (2023). Using Machine Learning Technique, Tracing the Actual Location of Faults in Underground Optical Networks. *9th International Conference on Smart Computing and Communications: Intelligent Technologies and Applications, ICSCC 2023*, 45–49. <https://doi.org/10.1109/ICSCC59169.2023.10335071>
- Battal, E., Ozkan, G., Savas, K., & Cakar, T. (2023). Fault Detection Model Using Measurement Data in Fiber Optic Internet Lines. *4th International Informatics and Software Engineering Conference - Symposium Program, IISEC 2023*. <https://doi.org/10.1109/IISEC59749.2023.10391036>
- Hosseini, S. E., Pervez, S., & Ansari, M. (2025). Enhancing Network Stability: Anomaly Detection in Performance Issues Within Mobile Networks. *International Conference on Applied Electronics*. <https://doi.org/10.1109/AE66163.2025.11197789>
- Issa, A., Kandil, N., & Hakem, N. (2023). Deep Learning-based Anomaly Detection for 5G Core Mobility Management. *2023 5th International Conference on Advances in Computational Tools for Engineering Applications, ACTEA 2023*, 25–29. <https://doi.org/10.1109/ACTEA58025.2023.10194147>
- Johari, S. S., Tornatore, M., Shahriar, N., Boutaba, R., & Saleh, A. (2026). Active Learning for Transformer-Based Fault Diagnosis in 5G and Beyond Mobile Networks. *IEEE Transactions on Network and Service Management*. <https://doi.org/10.1109/TNSM.2025.3622149>
- Lakshmi, G., & Brindha, S. (2024). Mitigating Environmental Impacts on Optical Fiber Fault Detection Using Machine Learning. *4th International Conference on Power, Energy, Control and Transmission Systems: Harnessing Power and Energy for an Affordable Electrification of India, ICPECTS 2024*. <https://doi.org/10.1109/ICPECTS62210.2024.10780193>
- Li, Y. J., Li, J. Y., Kao, H. Y., & Tsai, Y. L. (2024). Fiber Optical Module Anomaly Detection Using Graph Deep Learning Model. *Proceedings of the 2024 IEEE International*
-

Conference on Computer, Information, and Telecommunication Systems, CITS 2024. <https://doi.org/10.1109/CITS61189.2024.10607993>

Malik, G., Dipto, I. C., Masood, M. U., Mohamed, M. C., Straullu, S., Bhyri, S. K., Galimberti, G. M., Pedro, J., Napoli, A., Wakim, W., & Curri, V. (2025). Intelligent Detection of Overlapping Fiber Anomalies in Optical Networks Using Machine Learning. LEOS Summer Topical Meeting. <https://doi.org/10.1109/SUM65312.2025.11121809>

Malik, G., Masood, M. U., Cheruvakkadu Mohamed, M., Straullu, S., Bhyri, S. K., Maria Galimberti, G., Pedro, J., Napoli, A., Wakim, W., & Curri, V. (2025). Machine Learning for Predictive Multi-Event Detection in Fiber Optic Systems. 2025 IEEE International Conference on Machine Learning for Communication and Networking, ICMLCN 2025. <https://doi.org/10.1109/ICMLCN64995.2025.11140455>

Nakamura, K., & Higashino, T. (2025). A New Fault Detection Method Using Machine Learning in Analog Radio-on-Fiber MIMO Transmission System. IEICE Communications Express, 14(05), 174–176. <https://doi.org/10.23919/COMEX.2025XBL0015>

Patel, R., Narmawala, S., Mahida, N., Gupta, R., Tanwar, S., & Shahinzadeh, H. (2024). ML-based Optical Fibre Fault Detection in Smart Surveillance and Traffic Systems. 15th International Conference on Information and Knowledge Technology, IKT 2024, 216–221. <https://doi.org/10.1109/IKT65497.2024.10892793>

Sadighi, L., Karlsson, S., Natalino, C., & Furdek, M. (2026). ML-Based State of Polarization Analysis to Detect Emerging Threats to Optical Fiber Security. IEEE Transactions on Network and Service Management. <https://doi.org/10.1109/TNSM.2025.3607022>

Vinh, T. Q., Quan, D. V., Thanh, D. N., Trung, L. Q., & Huong, T. T. (2024). An Efficient Lightweight Anomaly Detection for 5G Core Network. Digest of Technical Papers - IEEE International Conference on Consumer Electronics. <https://doi.org/10.1109/ICCE59016.2024.10444414>

Yuan, Y., Yang, J., Duan, R., Chih-Lin, I., & Huang, J. (2020). Anomaly Detection and Root Cause Analysis Enabled by Artificial Intelligence. 2020 IEEE Globecom Workshops, GC Wkshps 2020 - Proceedings. <https://doi.org/10.1109/GCWKSHPS50303.2020.9367508>

Zhu, T., Narusue, Y., & Morikawa, H. (2024). Fault Diagnosis Using Hybrid Transfer Learning for VNF-based 5G Core Networks. 2024 IEEE Conference on Network Function Virtualization and Software Defined Networks, NFV-SDN 2024. <https://doi.org/10.1109/NFV-SDN61811.2024.10807503>
