

# 自由空间光通信的异常检测、分类与定位深度学习架构

宋嵩<sup>1,2</sup>, 吴廷伟<sup>2</sup>, 赵伦<sup>1,2</sup>, 贾家庆<sup>1,2</sup>, 郭磊<sup>1,2</sup>

(1. 重庆邮电大学通信与信息工程学院, 重庆 400065; 2. 重庆邮电大学智能通信与网络安全研究院, 重庆 400065)

**摘要:** 自由空间光 (FSO) 通信系统在实际传输过程中易受到湍流变化、光束对准误差及障碍遮挡等多种异常因素影响, 从而导致信号质量下降及传输性能退化。为此, 提出了一种基于深度学习的 FSO 系统异常检测、分类与定位框架——双域特征多任务网络 (DFMT-Net)。该框架融合了自注意力机制与高级特征提取技术, 能够对 FSO 信号中的多种异常类型进行精准检测与定位。同时, 引入基于重构误差的定位方法以提升定位精度。实验表明, DFMT-Net 在异常检测中的 F1 分数达到 0.99, 较极端梯度提升 (XGBoost) 和长短期记忆网络 (LSTM) 分别提升 47.76% 和 13.79%; 在异常诊断与遮挡定位任务中准确率分别为 99% 和 96.1%, 验证了所提框架的有效性与鲁棒性。

**关键词:** 自由空间光通信; 异常检测; 深度学习; 大气湍流

中图分类号: TN929.1

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025197

## Deep learning architecture for anomaly detection, classification, and localization in free-space optical communication

SONG Song<sup>1,2</sup>, WU Tingwei<sup>2</sup>, ZHAO Lun<sup>1,2</sup>, JIA Jiaqing<sup>1,2</sup>, GUO Lei<sup>1,2</sup>

1. School of Communications and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

2. Institute of Intelligent Communications and Network Security, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

**Abstract:** Free-space optical (FSO) communication systems are susceptible to various anomalies such as atmospheric turbulence, beam misalignment, and obstructions during transmission, resulting in signal degradation and performance deterioration. To address these issues, a deep learning-based framework named dual-domain feature multi-task network (DFMT-Net) was proposed for anomaly detection, classification, and localization in FSO systems. The framework integrated self-attention mechanisms with advanced feature extraction techniques to enable accurate detection and localization of multiple types of anomalies in FSO signals. Additionally, a reconstruction error-based localization method was introduced to improve localization accuracy. Experimental results show that DFMT-Net achieves an F1-score of 0.99 in anomaly detection, representing an improvements of 47.76% over extreme gradient boosting (XGBoost) and 13.79% over long short-term memory (LSTM) networks. It also attains 99% accuracy in anomaly diagnosis and 96.1% in obstruction localization, demonstrating the effectiveness and robustness of the proposed framework.

**Keywords:** free-space optical communication, anomaly detection, deep learning, atmospheric turbulence

收稿日期: 2025-08-07; 修回日期: 2025-10-16

通信作者: 吴廷伟, wutw@cqupt.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62401092, No.62301097, No.62025105, No.U24A20216); 中国博士后科学基金资助项目 (No.2024M763913); 重庆市科学技术局基金资助项目 (No.CSTB2024NSCQ-MSX0991); 重庆市教育局基金资助项目 (No.KJQN202400630); 重庆市人力资源和社会保障局基金资助项目 (No.2024CQBSHTB3072); 光纤传感与通信教育部重点实验室开放基金资助项目 (No.ZYGX2024K010)

**Foundation Items:** The National Natural Science Foundation of China (No.62401092, No.62301097, No.62025105, No.U24A20216), The China Postdoctoral Science Foundation (No.2024M763913), The Chongqing Municipal Science and Technology Bureau (No.CSTB2024NSCQ-MSX0991), The Chongqing Municipal Education Commission (No.KJQN202400630), The Chongqing human resources and Social Security Bureau (No.2024CQBSHTB3072), The Exchange Project for Key Lab of Optical Fiber Sensing and Communications (Ministry of Education of China) (No.ZYGX2024K010)

## 0 引言

5G 与 6G 通信网络的快速发展, 突显了通信架构在效率、灵活性与安全性方面的关键重要性。据爱立信预测, 到 2028 年, 全球单个智能手机的平均每月数据流量将达到 46 GB; 到 2030 年, 全球移动用户数量有望突破 170 亿<sup>[1]</sup>。随着通信网络对高速率、低时延需求的不断增长, 自由空间光 (FSO, free-space optical) 通信与无线电技术融合的“无线电-自由空间光”(RoFSO, radio over free-space optics) 通信技术凭借其高带宽、易部署和抗电磁干扰等优势, 成为突破传统光纤通信瓶颈的重要技术方案<sup>[2-5]</sup>。

然而, RoFSO 系统同样面临一系列独特的安全挑战。由于光信号在自由空间中传播, 极易受到多种环境因素的影响, 如大气湍流、散射, 以及由雨雾等恶劣天气导致的信号衰减, 同时还包括系统层面的问题, 如指向误差和束腰-接收孔径不匹配等<sup>[6]</sup>。这些因素不仅威胁信号传输的稳定性, 也对通信的保密性构成潜在风险。尽管 FSO 信号具备较高的方向性, 从而提升了抗窃听能力, 但若接收光束的发散区域过大, 仍可能导致散射激光被非法窃取, 从而存在信息泄露风险<sup>[7]</sup>。此外, 在接收束腰尺寸显著大于接收孔径的场景中, 激光束更容易受到大气湍流的干扰, 进一步增加了被窃听的可能性<sup>[8]</sup>。

现有研究多数集中于传统的密码算法层面<sup>[9-11]</sup>, 而对物理层安全机制的探索相对不足。FSO 系统在防范攻击与窃听方面仍然存在漏洞, 如何在保障通信质量的同时, 提升系统对异常事件的识别与响应能力, 成为 FSO 系统亟待解决的重要课题<sup>[12]</sup>。在实际传输中, FSO 链路易受到多种异常因素影响, 导致信号衰减、性能下降甚至中断。如图 1 所示, 根据来源不同, 这些异常可分为 3 类: 环境异常、系统异常以及遮挡类异常。环境异常主要包括大气湍流、降雨、降雪和浓雾等, 会引起信号衰减、闪烁或链路中断; 系统异常通常源于内部组件故障或光束对准与监测机制偏差, 常表现为信号特征(如均值、方差)的突变或持续性失真; 遮挡类异常则指在光束传播路径上出现临时阻碍或散射等情况, 导致信号出现异常波动甚至链路中断。在 5G 前传链路等高可靠性场景下, 若不能对上述异常进行及时检测与定位, 可能引发数据丢失、通信中断甚至

安全泄露。因此, 实现实时信道质量监测、快速异常告警与定位, 并在不显著增加系统负担的前提下动态调整系统参数, 是当前 FSO 系统中的关键研究问题之一。此外, 异常检测的复杂性还体现在“正常行为区域”的定义上。由于正常与异常的边界常常模糊, 且攻击者可能故意隐藏异常行为, 加之信号噪声与高维数据稀疏性, 使得传统的异常检测方法难以准确建模真实分布<sup>[13]</sup>。

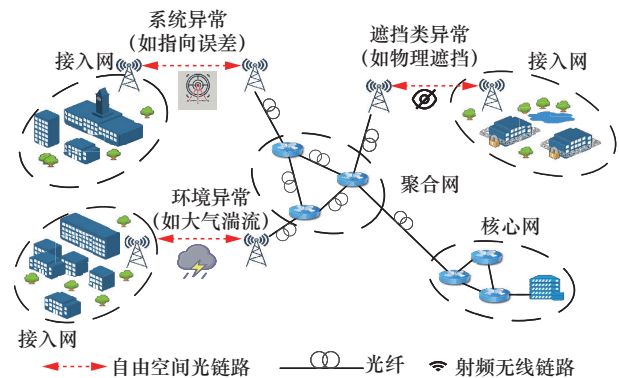


图1 5G架构下的FSO应用

近年来, 机器学习与深度学习技术的快速发展, 为FSO异常检测提供了新的思路。它们已在信道建模<sup>[14-16]</sup>、星座映射<sup>[17-19]</sup>, 以及信号补偿<sup>[20-22]</sup>等任务中展现出优异性能。当前的异常检测方法大多基于数据驱动思想, 可分为有监督与无监督2类。有监督方法依赖标签样本, 通过预测值与观测值的差异判定异常, 例如, Gong等<sup>[23]</sup>利用神经网络分析频谱特征以检测拒绝服务攻击; Song等<sup>[24]</sup>基于时域信号提取5维特征并训练长短期记忆网络(LSTM, long short-term memory), 在单模光纤窃听检测中准确率达95.83%; Liu等<sup>[25]</sup>提出一种结合粗滤模块的自编码器方法, 实现频谱数据压缩与异常检测; Abdelli等<sup>[26-27]</sup>采用基于LSTM的多任务学习框架, 结合光时域反射仪和双向门控循环单元(BiGRU, bidirectional gated recurrent unit)网络进行光纤故障检测与定位, 方法分别达到了93%和98.2%的检测准确率, 定位的均方根误差分别为2.17 m与0.19 m; Allogba等<sup>[28]</sup>利用四分位数与随机森林、支持向量机等方法实现早期信噪比异常检测, F1分数达0.995 1; 文献<sup>[29]</sup>提出注意力机制门控循环单元模型实现半导体激光器的健康状态预测, 异常检测准确率为94.24%。

然而, 在FSO系统中, 有监督方法的应用受

到标注样本稀缺与数据不平衡的制约。相较之下,无监督方法则通过挖掘数据特征实现异常识别,不需要依赖标签信息<sup>[30]</sup>。例如, Yang 等<sup>[31]</sup>提出结合 LSTM 与深度神经网络的混合检测框架; Zhang 等<sup>[32]</sup>将注意力机制引入自编码器用于故障检测, F1 分数达 0.952 7; Li 等<sup>[33]</sup>基于支持向量机与卷积神经网络 (CNN, convolutional neural network) 对物理层攻击进行检测, 准确率达 98.54%; Yu 等<sup>[34]</sup>则提出一种多任务 CNN 模型, 用于光网络性能监测, 在信号识别任务中准确率达 100%, 在光信噪比检测任务中平均绝对误差仅为 0.262。

尽管这些研究在光纤通信中取得了良好效果, 但直接迁移至 FSO 系统仍面临挑战。FSO 信道具有高度动态性与多源干扰特性, 异常定义与检测难度显著提升。目前针对 FSO 的综合性异常检测研究相对匮乏, 现有方法多聚焦于单一类型异常, 缺乏一个同时具备检测、分类与定位功能的统一框架。为此, 本文提出了一种双域特征多任务网络 (DFMT-Net, dual-domain feature multitask network), 利用时频双域序列实现 FSO 传输链路的异常检测, 同时通过子任务进一步进行分类判断及遮挡源定位。本文的主要贡献如下。

1) 对异常类型与检测方法进行了理论分析, 考虑了恶意遮挡攻击对频谱与时间序列信号的影响, 并系统比较了多种检测方法。此外, 本文提出了一种自适应的异常检测阈值设定算法。

2) 构建了基于 DFMT-Net 的端到端 FSO 系统异常检测框架, 直接作用于波形层级。与传统仅处理时域或频域信号的方法不同, 本文融合了双域多尺度特征, 避免了手动特征提取与常规建模。

3) 实验部署了一个 12 Gbit/s 的双偏振 64 阶正交幅度调制 (64-QAM, 64-ary quadrature amplitude modulation) 调制的 FSO 系统。通过引入噪声注入子系统, 模拟湍流效应、指向误差及相位扰动等异常场景, 并通过实测数据验证了所提框架在恶意遮挡攻击及系统噪声条件下的高效异常检测能力。

## 1 系统理论分析

本节将简要介绍用于所提出异常检测框架的自由空间光通信系统模型, 如图 2 所示。信息源产生伪随机二进制序列作为输入数据流。经过正交幅度调制和双偏振复用后, 信号被调制到光束上进行自

由空间传输。在接收端, 经过光电转换和偏振分离后, 采用相干检测方式, 信号与本振激光混频后经过平衡探测器、模数转换和数字信号处理, 最终解调与解码恢复出传输数据。

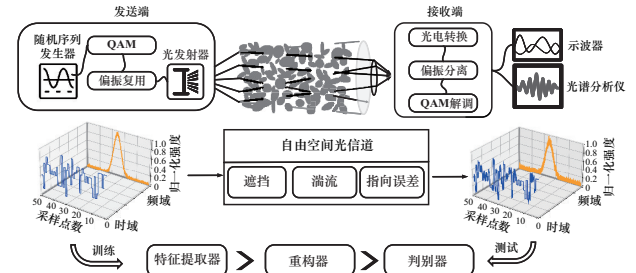


图2 FSO网络中的异常场景

示波器和光谱分析仪分别用于获取时间域和频率域的波形数据。具体的实验参数如表 1 所示, 聚焦于对 FSO 信道特性的分析, 这对于异常检测框架的构建与验证至关重要。这些分析有助于深入理解系统在正常与异常状态下的表现, 从而实现准确、可靠的异常检测。

表 1 FSO 实验的相关参数

实验参数	数值
比特率/(Gbit·s <sup>-1</sup> )	12
信号功率/dBm	10
序列长度/bit	16 384
传输距离/m	1 000
光波长/nm	1 550

### 1.1 大气湍流

光束在 FSO 信道传播过程中, 可能受到多种干扰的影响, 特别是大气湍流引起的信号畸变。大气湍流可以通过伽马-伽马分布 (G-G, gamma-gamma distribution) 进行有效建模。在该模型中, 给定光强  $I$  的概率密度函数<sup>[35]</sup>为

$$P(I) = \frac{2(\alpha\beta)^{\frac{(\alpha+\beta)}{2}}}{\Gamma(\alpha)\Gamma(\beta)} I^{\frac{\alpha+\beta}{2}-1} K_{\alpha-\beta}\left(2\sqrt{\alpha\beta I}\right) \quad (1)$$

其中,  $K_{\alpha-\beta}(\cdot)$  是第二类修正贝塞尔函数,  $\Gamma(\cdot)$  是 Gamma 函数,  $\frac{1}{\alpha}$  和  $\frac{1}{\beta}$  分别表示小尺度和大尺度湍流涡的方差。

$$\alpha = \exp \left[ \frac{0.49\sigma_R^2}{(1 + 1.11\sigma_R^{\frac{12}{5}})^{\frac{7}{6}}} \right] - 1 \quad (2)$$

$$\beta = \exp \left[ \frac{0.51\sigma_R^2}{(1 + 0.69\sigma_R^{\frac{12}{5}})^{\frac{5}{6}}} \right] - 1 \quad (3)$$

其中, 里托夫方差  $\sigma_R^2$  由折射率结构常数  $C_n^2$ 、链路长度  $l$  和光波数  $k$  计算得到。

$$\sigma_R^2 = 1.23C_n^2 k^{\frac{7}{6}} l^{\frac{11}{6}} \quad (4)$$

## 1.2 指向误差

激光束在 FSO 信道传播过程中, 可能受到多种干扰的影响, 尤其是由于大气湍流引起的信号畸变。风力引起的建筑物摆动和热膨胀等因素导致的随机光束偏移, 会造成指向误差, 从而在接收端引发显著的信号衰落。假设垂直方向和水平方向上的指向误差抖动是相互独立且服从相同分布的, 其抖动可用期望为 0、方差为  $\sigma_s^2$  的高斯分布表示。

接收端激光束的径向位移服从瑞利分布, 因此, 指向误差损耗  $h_p$  的概率密度函数为<sup>[36]</sup>

$$f_{h_p}(h_p) = \frac{\gamma^2}{A_0^2} h_p^{\gamma^2 - 1}, \quad 0 \leq h_p \leq A_0 \quad (5)$$

其中,  $\gamma$  表示接收端等效光束半径与指向误差偏移标准差的比值, 定义为

$$\gamma = \frac{w_{z\text{ep}}}{2\sigma_s} \quad (6)$$

其中,  $w_{z\text{ep}}$  是接收端的等效光束宽度,  $\sigma_s$  为指向误差偏移的标准差。 $w_{z\text{ep}}$  考虑了大气条件和光束传播效应, 其计算式为<sup>[36]</sup>

$$w_{z\text{ep}}^2 = w_z^2 \sqrt{\pi} \frac{\text{erf}(v)}{2v \exp(-v^2)} \quad (7)$$

其中,  $v = \frac{\sqrt{\pi} a}{\sqrt{2} w_z}$ ,  $a$  为探测器的半径,  $w_z$  为发射器距离  $z$  处的光束腰宽;  $\text{erf}(v)$  为误差函数,  $A_0 = [\text{erf}(v)]^2$  表示接收端归一化的激光束面积。接收端指向误差偏移的标准差  $\sigma_s$  表征了由于环境扰动引起的抖动方差。

**1.3 遮挡效应**

在自由空间中光束传播过程中, 设在传播距离为  $z$  处存在一个障碍物。假设该障碍物的尺寸与分布已知, 当光束穿过障碍物时将被分为 2 个部分。

一部分光束在障碍物周围的能量会在更大的空间中扩散, 并在通过障碍物后逐渐恢复到光束中心继续传播; 另一部分光束则可直接穿透障碍物继续传播。障碍物后距离为  $\Delta z$  的位置处接收到的光场  $U(x,y,z + \Delta z)$  可表示为

$$U(x,y,z + \Delta z) = \mathcal{F}^{-1} \{ \mathcal{F} [ U(x,y,z) \mathbf{O}(x,y) ] H(f) \} \quad (8)$$

其中,  $\mathbf{O}(x,y)$  为障碍物的复振幅透过函数, 是仅由 0 与 1 组成的二值掩码矩阵,  $H(f)$  为通过菲涅尔衍射传播的传递函数, 其形式为

$$H(f) = e^{ik\Delta z} e^{-j\pi\Delta z(f_x^2 + f_y^2)} \quad (9)$$

其中,  $f_x$  与  $f_y$  分别表示在  $x$  和  $y$  方向上的频率。

## 1.4 异常识别机制

为了对多种异常进行量化, 需定义一种度量数据偏差的机制。设有 2 个时间序列  $X = (x_1, x_2, \dots, x_n)$  与  $Y = (y_1, y_2, \dots, y_n)$ , 常用的度量方式之一为欧氏距离, 其定义为

$$d_{\text{Euclidean}}(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (10)$$

该度量衡量原始序列与重构序列之间的均方根误差, 提供整体的偏差度量。而对于离散点之间的差异, 切比雪夫距离更为合适, 它衡量 2 个序列对应元素间的最大绝对差值。

$$d_{\text{Chebyshev}}(X, Y) = \max_i (|x_i - y_i|) \quad (11)$$

另一种度量方法为库尔巴克-莱布勒 (KL, kullback-leibler divergence) 散度, 用于衡量 2 个概率分布之间的差异, 定义为

$$d_{\text{KL}}(X, Y) = \sum_{i=1}^n x(i) \log \left( \frac{x(i)}{y(i)} \right) \quad (12)$$

KL 散度是一种非对称度量, 能反映两个概率分布之间的发散程度, 从而提供两者之间差异的深层信息。动态时间规整 (DTW, dynamic time warping) 是一种相似度度量方法, 适用于比较具有不同长度或节奏的时间序列数据。两个点之间 DTW 距离为

$$D(i, j) = (x_i - y_j)^2 \quad (13)$$

其序列累积距离通过递归计算得到

$$D(i, j) = (x_i - y_j)^2 + \min(D(i-1, j), D(i, j-1), D(i-1, j-1)) \quad (14)$$

最终, 两序列  $X$  与  $Y$  之间的总 DTW 距离定义为

$$d_{\text{DTW}}(X, Y) = D(n, n) \quad (15)$$

### 1.5 物理模型与数据驱动范式

前文从物理层面建立了大气湍流、指向误差及遮挡效应的数学模型, 这些模型揭示了物理扰动影响光场与光强的基本原理。在本文提出的数据驱动框架中, 这些物理层面的影响最终将体现为接收端时域功率波形与频域采样信号的特征变化。具体而言, 上述理论模型是数据生成的基础, 通过 G-G 分布可生成具有特定闪烁指数的时域光强序列, 而菲涅尔衍射模型则可用于模拟遮挡引入的时域波形畸变与频谱分量变化。这些生成的、蕴含了物理扰动特性的信号序列, 构成了后续框架的直接输入。在此基础上, 1.4 节介绍的异常量化方法为量化正常信号与异常信号之间的差异提供了数学工具。DFMT-Net 作为一个数据驱动的引擎, 其核心任务并非直接求解复杂的物理公式, 而是以这些受扰动的信号为输入, 自主学习其在高维特征空间中的表征。DFMT-Net 通过重构误差和多任务学习, 发现并区分由不同物理原因导致的、具有不同统计特性的异常模式。

## 2 框架设计与实现

如图 3 所示, DFMT-Net 架构主要包括 5 个阶段: 光信号监测与数据采集、数据处理、光信号特征提取、光信号异常检测和系统异常诊断与定位。在端到端的 FSO 系统中, 激光设备部署完成后, 在恒定发射功率下对接收信号的功率和频谱进行持续监测。采集到的时域信号功率波形与频域采样信号序列将被存储至数据库中。

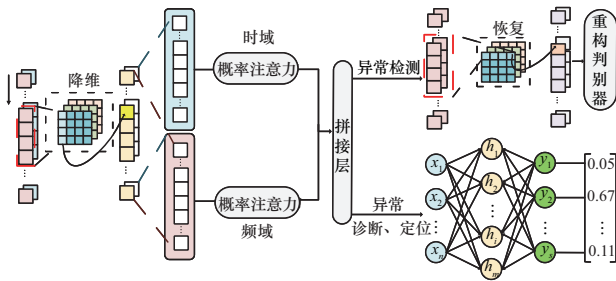


图 3 DFMT-Net 架构

接下来, 从正常通信中选取的信号测量值  $O = \{o_1, o_2, \dots, o_N\}$  经过预处理后输入至模型进行训练, 以

学习信道传输特性, 其中  $o_i = \{t_i, f_i\}$  表示在时域与频域上采样得到的信号。模型基于输入的信号测量值对序列进行重构, 以实现异常检测。重构后的序列随后被送入异常检测模块, 根据预定义的异常行为标准进行分类。为应对不同类型异常的影响, 系统引入多种度量指标, 以判断行为是否异常。此外, DFMT-Net 还能识别并分类严重的异常, 如遮挡、光路偏移误差和大气湍流等。在处理与遮挡相关的异常时, 模型还具备精确估计遮挡位置的能力。后文将详细介绍所提框架中各模块的结构与工作原理。

### 2.1 特征提取与通道混合器

图 4 展示了所提出的用于信号特征提取的降维混合器结构。输入为长度为  $N$  的信号序列  $O$ , 首先根据其调制方式对序列进行重组, 并根据符号到比特的映射关系对数据进行分组。例如, 对于 64QAM, 每个 QAM 符号编码 6 bit 信息, 则  $C = 12$ ,  $S = \frac{N}{C}$ , 每组的  $l_i$  通过式(16)转换进行投影。

$$\mathbf{G} = \text{reshape}(O, (S, C)), S = \frac{N}{C} \quad (16)$$

其中,  $\mathbf{G} \in \mathbb{R}^{S \times C}$  表示一个二维矩阵, 包含  $S$  个符号, 每个符号被表示为  $C$  维特征向量, 包含  $I/Q$  两路信号的信号特征, 提供信号  $I/Q$  两路的幅度与偏移量的参考和统计特征。每个符号  $g_i$  通过式(17)变换投影到一个高维空间中。

$$\mathbf{h}_i = \mathbf{W}_{\text{embed}} \cdot \mathbf{g}_i + \mathbf{b}_{\text{embed}} \quad (17)$$

其中,  $\mathbf{W}_{\text{embed}} \in \mathbb{R}^{d_{\text{in}} \times d_{\text{embed}}}$  是嵌入矩阵,  $\mathbf{b}_{\text{embed}}$  是偏置项,  $\mathbf{h}_i$  表示符号  $g_i$  的高维特征表示。所有符号的高维表示组合后形成矩阵  $\mathbf{H} \in \mathbb{R}^{S \times d_{\text{embed}}}$ 。




图 4 信号特征提取的降维混合器结构

为了嵌入特征, 本文应用了具有不同卷积核大小  $k \in 3, 5, 7$  的通道混合器, 通过适当的填充操作保证输出序列的长度一致, 并在之后进行批量归一化, 以加速神经网络计算并提高训练稳定性, 具体为

$$\mathbf{H}_{\text{conv}}^{(k)} = \text{conv1d}(\mathbf{H}, \mathbf{W}_{\text{conv}}^{(k)}, k) \quad (18)$$

其中,  $\mathbf{W}_{\text{conv}}^{(k)}$  表示对应核大小  $k$  的卷积权重,  $\text{conv1d}(\cdot)$  表示一维卷积操作。不同卷积核大小的输出拼接以形成混合特征。

$$\mathbf{H}_{\text{mix}} = [\mathbf{H}_{\text{conv}}^{(3)}, \mathbf{H}_{\text{conv}}^{(5)}, \mathbf{H}_{\text{conv}}^{(7)}] \quad (19)$$

对混合特征进行批归一化处理

$$\mathbf{H}_{\text{norm}} = \frac{\mathbf{H}_{\text{mix}} - \mu}{\sqrt{\sigma^2 + \epsilon}} \quad (20)$$

其中,  $\mu$  和  $\sigma^2$  表示该批次的均值与方差,  $\epsilon$  是用于防止除以零的微小常数。

随后, 使用线性投影将数据下采样至目标潜在维度  $D$ , 以减少网络参数带来的计算复杂度。

$$\mathbf{H}_{\text{out}} = \mathbf{W}_{\text{down}} \cdot \mathbf{H}_{\text{norm}} + \mathbf{b}_{\text{down}} \quad (21)$$

其中,  $\mathbf{W}_{\text{down}}$  是尺寸为  $[d_{\text{mix}}, D]$  的权重矩阵,  $\mathbf{b}_{\text{down}}$  是偏置项。最终得到的输出特征  $\mathbf{H}_{\text{out}} \in \mathbb{R}^{S \times D}$ , 提供了对原始输入数据的低维、计算高效的表示。该混合器的重采样机制实现了多特征的有效提取, 并提升了结果的可解释性。

## 2.2 特征提取注意力机制

本文所提出的特征提取模块由 2 个编码器层组成, 中间由随机失活层进行连接。每个编码器层包含一个概率注意力模块和一个前馈网络模块。如图 5 所示, 每个模块之后都采用残差连接, 并接着进行层归一化, 以增强训练的稳定性并保证优化过程更加平滑。

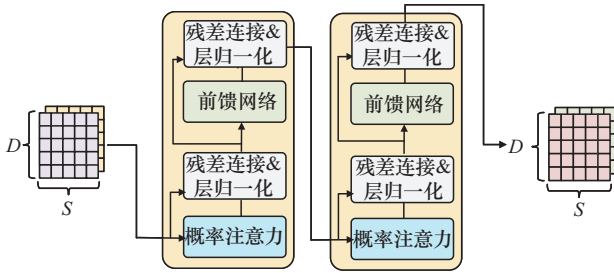


图5 概率注意力机制

概率注意力是一种基于文献[37]提出的方法改进而来的多头注意力机制。标准的注意力机制[38]定义为

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}}\right)\mathbf{V} \quad (22)$$

其中,  $\mathbf{Q} \in \mathbb{R}^{\mathcal{L}_Q \times d}$ 、 $\mathbf{K} \in \mathbb{R}^{\mathcal{L}_K \times d}$  和  $\mathbf{V} \in \mathbb{R}^{\mathcal{L}_V \times d}$  分别是查询、键和值矩阵,  $d$  是输入维度。概率注意力不计算完整的注意力矩阵, 而是通过稀疏度测量函数

$f(q_i)$  选择前  $k$  个查询。

$$f(q_i) = \|q_i\|_2 \cdot \text{lb}(1 + \|q_i\|_1) \quad (23)$$

其中,  $q_i \in \mathbb{R}^d$  是第  $i$  个查询向量,  $\|q_i\|_1$  和  $\|q_i\|_2$  分别表示其  $L_1$  范数和  $L_2$  范数。通过统计查询中的有效元素数量, 并结合异常特征的维度, 利用前  $q$  位选择算法限制的最大通道数量, 从而选择更重要的查询和键, 具体表示为

$$\mathcal{L}_u = \min(S, D, \log(\mathcal{L}_Q), \log(\mathcal{L}_K)) \quad (24)$$

其中,  $S$  是通道数,  $D$  是特征维度,  $\mathcal{L}_Q$  是查询序列长度,  $\mathcal{L}_K$  是键序列长度。得到的稀疏查询矩阵  $\bar{\mathbf{Q}} \in \mathbb{R}^{\mathcal{L}_u \times d}$  仅包含前  $k$  个查询。该方法特别适合处理高维或大规模数据, 具体表示为

$$\text{ProbAttention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\bar{\mathbf{Q}}\mathbf{K}^T}{\sqrt{d}}\right)\mathbf{V} \quad (25)$$

在输入序列长度为  $R$  的情况下, 可以将每一层的注意力时间复杂度从  $O(R^2)$  优化至  $O(R \text{lb} R)$ , 在保持预测精度的同时显著降低了计算复杂度。

## 2.3 多任务学习

多任务学习共享部分网络模型, 使不同任务不仅共享参数, 还能互相借鉴其他任务的信息。所提模型结合了通道混合特征提取和概率注意力机制, 以捕捉数据的分布特征和上下文信息。不同的下游网络用于执行不同的任务。

对于异常检测, 采用升维特征恢复模型进行数据重构。提取的特征通过不同大小的卷积核 (3、5、7) 处理, 随后进行批归一化和 GeLU 激活的非线性变换, 再进行下采样。不同卷积核的输出按式(26)求和。

$$\mathbf{H}_{\text{sum}} = \sum_{k \in \{3, 5, 7\}} \mathbf{H}_{\text{conv}}^{(k)} \quad (26)$$

融合后的特征进行符号级恢复, 并展平成一维序列用于最终重构。重构误差计算为

$$\text{Error} = \Theta(\mathbf{L}, \hat{\mathbf{L}}) \quad (27)$$

其中,  $\mathbf{L}$  是原始序列,  $\hat{\mathbf{L}}$  是重构序列。当误差超过预设阈值  $\theta$  时, 判断为异常。

$$\text{Anomalous} = \begin{cases} 1, & \text{误差} > \theta \\ 0, & \text{其他} \end{cases} \quad (28)$$

对于异常诊断, 不同类型的异常影响不同, 采用多层感知机对异常类型进行区分。符号特征通过全连接神经网络采样, 表示为

$$F_{\text{symbolic}} = \sigma(W_{\text{fc}} \cdot F_{\text{contact}} + b_{\text{fc}}) \quad (29)$$

其中,  $W_{\text{fc}}$  和  $b_{\text{fc}}$  分别是全连接层的权重矩阵和偏置,  $\sigma(\cdot)$  是激活函数,  $F_{\text{contact}}$  通过时域和频域特征进行拼接得到。

$$F_{\text{concat}} = [F_{\text{time}}, F_{\text{freq}}] \quad (30)$$

利用输出层判断异常类型。

$$\hat{y} = \text{Softmax}(W_{\text{out}} \cdot F_{\text{concat}} + b_{\text{out}}) \quad (31)$$

其中,  $W_{\text{out}}$  和  $b_{\text{out}}$  是输出层的参数。模型使用交叉熵损失函数进行训练。

$$\text{Loss}_{\text{CE}} = -\sum_i y_i \log(\hat{y}_i) \quad (32)$$

其中,  $y_i$  是真实标签,  $\hat{y}_i$  是类别  $i$  的预测概率。异常类型判定为

$$\text{Anomaly Type} = \arg \max(\hat{y}) \quad (33)$$

异常定位是异常诊断的一个子任务, 在通过物理通信链路中确定异常事件发生的大致物理位置区间。在信号被判定为异常后, 使用多层感知机对异常位置进行精确定位。输出类别表示为

$$\hat{p} = \text{Softmax}(W_{\text{loc}} \cdot F_{\text{input}} + b_{\text{loc}}) \quad (34)$$

其中,  $W_{\text{loc}}$  和  $b_{\text{loc}}$  是定位模型的参数。预测的异常区域为

$$\text{Region} = \arg \max(\hat{p}) \quad (35)$$

通过调整多层感知机中神经元的数量, 可以进一步提升定位精度。该方法将通信链路划分为  $R$  个区域, 实现了有效的异常分类。

### 3 实验评估

本节将通过数值实验结果验证所提模型的性能。

#### 3.1 实验数据

为构建用于模型训练的数据集, 本文结合了实验采集数据与仿真模拟数据。图 6 展示了正常、指向误差、遮挡以及湍流这 4 种典型场景下接收端波形的对比情况。其中, 基准正常信号的光谱和功率谱数据来源于在重庆市进行的 1 000 m 室外链路实测, 采集于晴朗、无雾的稳定夜间天气条件下, 温度约 24°C, 大气折射率结构常数  $C_n^2$  约为  $1 \times 10^{-14}$ , 发射端使用 1 550 nm 激光器, 接收端采用相干检测架构; 而湍流、指向误差及遮挡等异常场景通过数值仿真方法生成, 为确保仿真数据与实测数据的兼容性与分布一致性, 本文对实测的正常信号进行了

统计分析, 获取其均值、方差等关键特征, 并利用这些真实数据来设定仿真模型中的关键参数。为模拟湍流引起的异常影响, 基于不同的大气相干长度  $r_0$  构建了不同湍流强度下的大气湍流相位屏幕, 并生成其对应的畸变光束强度分布, 分别对应 3 种湍流强度水平  $C_n^2 = 1 \times 10^{-14}$ ,  $C_n^2 = 1 \times 10^{-13}$  和  $C_n^2 = 5 \times 10^{-14}$ , 由此产生了额外的 1 080 个数据向量。引入了周期性抖动来量化指向误差, 并基于高斯分布下的平均径向水平和垂直偏移获得了 FSO 系统异常对准情况。遮挡相关异常数据则通过在预设的端到端链路中, 基于相位屏幕模型构造光束扰动强度分布, 在不同信道位置引入同分布噪声和相位扰动, 模拟障碍物对通信信道的干扰。在具体的数值实现中, 采用相位屏方法, 并结合一个符合障碍物物理分布的随机二维光场强度矩阵, 来模拟光束穿过障碍物后的光场。该方法产生的受扰光场, 其统计特性被用于生成最终施加于时域和频域信号上的噪声与相位抖动, 从而在信号层面复现遮挡的实际影响, 以此建立理论模型与仿真操作之间的清晰映射。

最终, 构建的数据集共包含 12 690 组数据向量, 其中正常样本占比为 75%, 其余 25% 异常样本均匀分布于 3 类异常场景: 指向误差、遮挡以及湍流。

#### 3.2 异常检测性能评估

本文模型用于从收集的数据集中提取与重构特征。为保证评估的公正性, 本文采用了分层抽样的方法进行样本划分, 以确保训练集与测试集中各类样本的分布比例保持一致。其中, 80% 的正常样本被用于模型训练, 其余 20% 的正常样本以及全部异常样本构成测试集, 用于评估模型在异常检测任务中的性能表现。通过调整网络参数及训练超参数, 对神经网络进行了优化, 旨在模型复杂度与分类准确率之间取得良好平衡。在对比不同模型下的异常分类准确率后, 最终确定了模型的关键参数配置: 模型维度设定为 192, Mixer 模块的维度为 64, 注意力头数  $n_{\text{heads}}$  和层数  $n_{\text{layers}}$  分别为 4 和 2。初始学习率设定为  $1 \times 10^{-5}$ , 并在每个训练轮次中以 0.95 的衰减因子逐步下降。优化器选用 Adam, 同时引入 L2 正则化项, 正则化系数为  $\beta = 0.01$ , 以缓解模型在训练集上的过拟合风险。损失函数选用均方误差 (MSE, mean-square error) 以衡量重构序列的误差。在测试过程中, 模型被切换至评估模式,

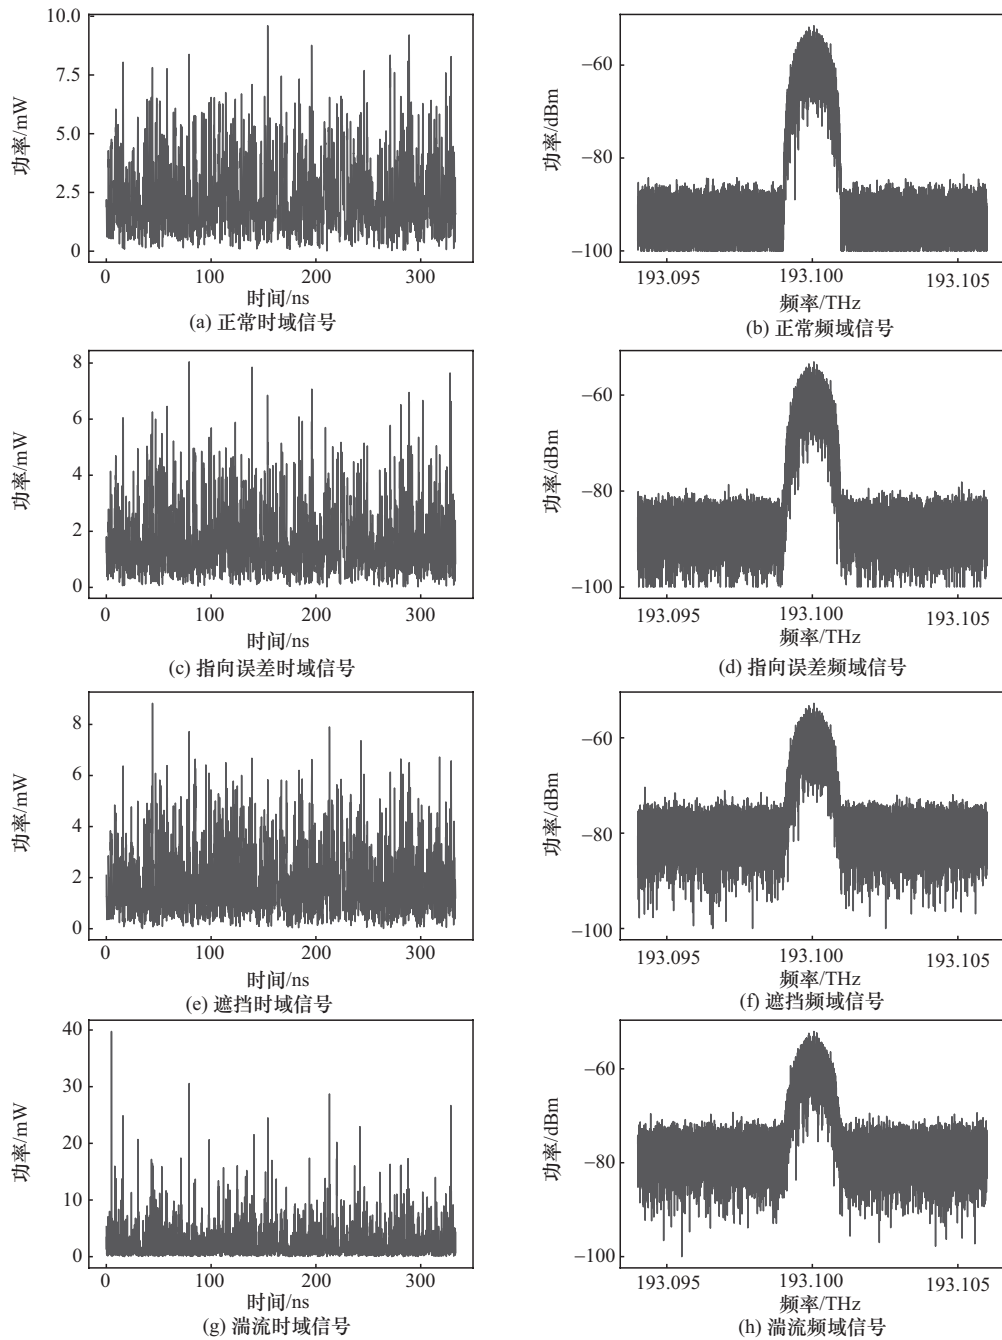


图6 功率波形与频谱图

禁用随机失活层与归一化等随机性模块，确保结果的确定性。

图7为训练过程中损失函数与准确率的变化趋势。其中，训练损失表示模型在正常训练样本上的均方误差损失，验证损失为在未见过的正常样本上的验证损失，异常损失则为在未见异常样本上的重构误差。随着训练轮次增加，模型对正常数据分布的拟合能力逐渐提升，训练损失与验证损失均显著下降后趋于稳定；而在异常数据上的重构误差

始终维持在较高水平，表明模型未能有效拟合异常分布。准确率与F1分数曲线反映了模型对异常样本的分类性能，两者均随训练进程稳步上升，最终达到稳定状态，分类准确率接近100%，表明模型具有良好的异常识别能力。

图8为模型在正常与异常信道条件下的典型重构结果。为便于观察，图中仅绘制了原始波形中提取的200个时域点作为代表样本。图8(a)为正常情况下的重构结果，可见原始信号与重构信号高度一

致, 误差较小, 说明模型能够有效还原正常信号。而在图 8(b)所示的异常条件下, 原始信号与重构信号存在明显偏差, 误差幅度显著增加。这表明模型对异常具有较强的敏感性, 能够准确捕捉干扰因素引起的信号异常, 体现其良好的检测能力。




图7 训练过程中损失函数与准确率的变化趋势




图8 模型在正常与异常信道条件下的典型重构结果

### 3.3 异常阈值判别分析

自由空间光通信系统信道特性具有高度随机性, 即使相同链路在不同时间的测试结果也可能不同。因此, 区分由信道波动引起的变化与真实异常尤为重要, 这也为实际检测带来挑战。尽管 DFMT-Net 具备良好识别能力, 仍存在漏检或误判的可能, 这是检测中难以完全避免的。为更客观地评估性能, 本文采用准确率和 F1 分数作为指标。F1 分数综合精确率与召回率, 基于真正例 (TP, true positives)、假正例 (FP, false positives) 和假负例 (FN, false negatives) 计算, 全面反映检测效果。

在计算 F1 分数之前, 首先需要通过式(36)、式(37)分别计算精确率和召回率。

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (36)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (37)$$

然后通过式(38)将两者结合, 得到 F1 分数, 其为精确率与召回率的调和均值。

$$\text{F1} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (38)$$

该指标在样本不平衡的场景中尤为有效, 因其在降低假阳性率与假阴性率之间取得较好权衡。在 FSO 系统的异常检测任务中, F1 分数可对模型的分类能力进行综合评估。此外, 本文还引入准确率作为补充评估指标, 其定义为被正确分类的样本数量与样本总数之比。

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (39)$$

为进一步直观展示 DFMT-Net 的有效性, 本文构建了重构能量分布图。通过整合式距离度量, 包括欧氏距离、KL 散度、切比雪夫距离和 DTW 距离, 构建统一的评分准则  $\Theta$ , 定义为

$$\Theta = \alpha d_{\text{eucl}} + \beta d_{\text{cheby}} + \lambda d_{\text{KL}} + \gamma \text{lb}(d_{\text{DTW}}) \quad (40)$$

如图 9 所示, 该评分准则将数据依据重构误差分为 4 类, 从而有效可视化数据向量的分布。评估结果显示, 基于重构误差的分类方法能够成功识别大部分异常样本, 并在保持较低误判率与漏判率的同时实现高精度性能。特别地, 模型在测试集上取得了 F1 分数为 0.991, 验证了其在异常检测中的高鲁棒性与准确性。




图9 基于重构误差的DFMT异常检测数据分布

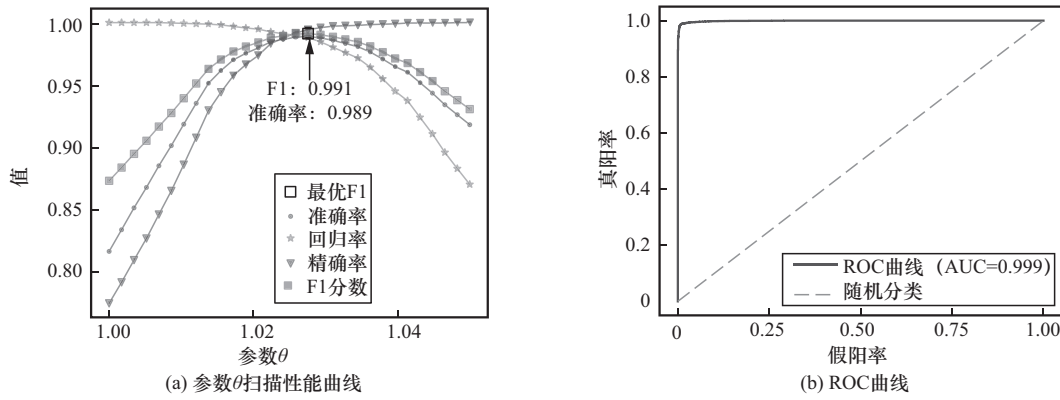


图10 DFMT-Net的性能曲线

通过对系数  $\alpha$ 、 $\beta$ 、 $\lambda$  和  $\gamma$  以及阈值参数  $\theta$  进行选择，本文进一步优化评分机制以有效量化异常程度。其中， $\alpha$  等权重参数用于调节各类距离度量对总评分的影响， $\theta$  则作为判断数据是否异常的关键阈值。值得注意的是，若对均方误差权重  $\alpha$  设置过高，则可能导致异常检测结果主要受 MSE 全局阈值控制，忽视了局部严重信号畸变；DTW 距离虽能有效捕捉序列间的时间错位与对齐特征，但若权重  $\gamma$  过大，则可能过度强化模型对信道特性扰动的拟合。相比之下，KL 散度可用于衡量序列间分布的整体差异，是衡量全局偏离度的重要指标。

经过对多组数据组合的实验分析，本文确定了一个最优的权重组合，即  $[\alpha, \beta, \lambda, \gamma] = [1, 1, 1, 1]$ ，以此获得最具效果的异常量化方式。图 10(a) 展示了  $\theta$  与检测性能之间的关系。从图 10(a) 可以看出，精确率与召回率之间存在权衡。当  $\theta$  超过 1.05 时，许多正常样本被误判为异常，导致假阴性增加、召回率下降；相反，若  $\theta$  与低于 1，则部分异常样本被误判为正常，导致假阳性增多、精确率下降。因此，最佳阈值应能在精确率与召回率之间取得平衡，从而最大化 F1 分数。实验表明，当最优阈值  $\theta$  与设为 1.028 时，模型在测试集上表现如下：准确率为 0.989，召回率为 0.9879，精确率为 0.9944，F1 分数为 0.9912。图 10(b) 为该模型在不同阈值下的受试者操作特征 (ROC) 曲线。结果表明，DFMT-Net 对正常与异常样本具有良好的区分能力，曲线下的面积 (AUC) 达到了 0.99，说明模型具有高度可分性。

### 3.4 异常诊断与定位性能评估

DFMT-Net 通过共享主干网络来增强各任务之间的相关性。前文训练得到的特征提取器与概率注

意力模块的参数被保存并在本阶段中重新加载，且在训练过程中保持冻结状态。下游网络由一个包含 128 个隐藏神经元的全连接层和一个包含 9 个神经元的输出层组成，损失函数采用交叉熵以实现有效的模型训练。

为了定性分析不同类型异常在数据集中的分布，本文采用了 t 分布随机邻域嵌入 (t-SNE, t-distributed stochastic neighbor embedding) 技术，将高维特征映射到二维空间中进行可视化。图 11 展示了在不同特征嵌入条件下，指向误差、障碍遮挡和湍流所导致的异常的特征分布。当仅进行归一化处理时，所学习到的特征区分性较差，湍流类异常易与指向误差和障碍遮挡类混淆。这主要是因为光强波动导致不同异常模式之间的差异被掩盖。引入所提出的主干网络进行特征提取后，提取出的特征具备更好的区分能力，尽管异常诊断结果仍存在重叠。通过进一步引入定位子网络，所提框架能够学习到更加有效的特征，从而提升故障诊断的准确性。

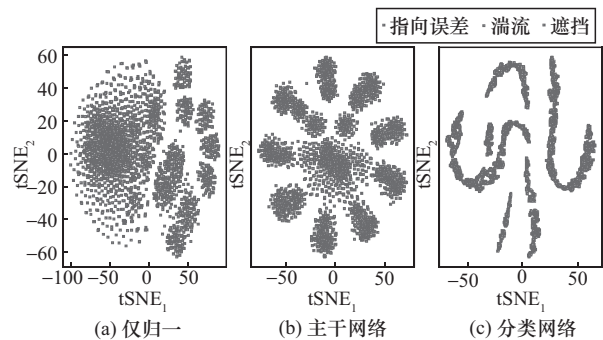


图11 特征表示的t-SNE可视化

DFMT-Net 在多类异常诊断任务中表现出色，如图 12 所示，整体准确率超过 0.98。然而，在中度扰动的情况下，其异常重构模式与对准误差较为

相似, 导致该类别出现一定程度的误分类。同样地, 遮挡类异常在中度扰动条件下也会受到影响, 从而导致误分类率上升。

真实值	指向误差	1 087	8	11
	湍流	7	1 025	31
	遮挡	0	4	1 027
		指向误差	湍流	遮挡
		预测值		

图 12 DFMT-Net 在异常诊断中的表现

在异常定位任务中, 为在定位粒度与模型复杂度之间取得平衡, 本文通过在一条 1 km 的通信链路上以每 100 m 间隔布置障碍物, 构建了 9 个不同位置的异常类别数据集, 以验证所提框架的鲁棒性。在该阶段, 同样冻结主干网络的参数, 并调整子网络模型, 使其输出一个长度为 9 的向量, 表示预测异常发生在链路中距接收端不同距离位置的概率。图 13 展示了所提出定位网络在测试集上的表现。DFMT-Net 展现出强大的异常定位能力, 在准确识别异常位置方面达到了 0.961 的高准确率, 同时保持极低的误分类率。上述实验结果验证了该框架在不同任务中的优越性能, 表明其具备在不同空间位置检测各类异常的强大适应性。

0	141	0	0	0	0	0	0	0	0	
1	1	158	4	0	0	0	0	0	0	
2	0	1	127	1	2	0	0	0	3	
3	2	0	0	119	5	0	0	0	0	
4	0	0	0	3	132	0	4	0	1	
5	0	0	0	0	2	166	0	0	0	
6	0	0	3	0	0	2	103	7	1	
7	0	0	0	0	0	3	0	139	1	
8	0	0	0	1	0	2	0	0	150	
		0	1	2	3	4	5	6	7	8
		预测值								

图 13 用于异常定位的 DFMT-Net 性能

为进一步探讨定位间隔对模型性能的影响。本文通过合并相邻位置类别的方式, 将原始的 100 m

间隔数据集重组为 200 m 和 300 m 间隔的数据集, 并分别评估了模型的定位准确率。从表 2 可以看出, 随着定位间隔的增大, 分类任务的类别数量减少, 模型的定位准确率也相应从 0.961 (100 m 间隔) 提升至 0.984 (300 m 间隔)。该结果量化地验证了定位间隔的选择是在定位粒度与定位准确率之间的一种权衡。在实际应用中, 可根据对定位精度的具体需求来选择合适的模型。本文选择 100 m 作为研究的重点, 旨在探索模型在高精度定位场景下的性能边界, 而实验结果 (0.961) 也证明了 DFMT-Net 在该设定下依然具有强大的定位能力。

表 2 不同定位间隔下的模型性能对比

定位间隔/m	类别数量	准确率
100	9	0.961
200	4	0.976
300	3	0.984

### 3.5 DFMT-Net 与其他现有模型的对比分析

本文对比了几种常用的异常检测模型, 包括无监督学习算法如一类支持向量机 (OCSVM, one-class support vector machine)、监督学习算法如极端梯度提升 (XGBoost, extreme gradient boosting) 以及深度学习算法如 LSTM, 比较指标包括加权平均 F1 分数、准确率和均方误差。

OCSVM 在特征空间中学习正常数据的决策边界, 任何落在边界之外的样本均被判定为异常。本文采用径向基核函数将数据映射到高维空间, 以增强模型处理非线性问题的能力。OCSVM 仅使用正常数据进行训练, 并在测试阶段对包含正常与异常样本的未见数据进行评估。XGBoost 通过迭代构建决策树, 以最小化前一轮模型的残差, 并动态调整权重以减少误差。在异常检测任务中, 本文将归一化后的信号数据直接输入模型进行训练。信号尺寸由时域波形长度与频域采样宽度之和定义。具体参数设置为 150 棵决策树, 每棵树深度为 6, 学习率为 0.1, L1 正则化系数为 0.15。该模型使用标注的正常与异常数据进行训练, 并在未见数据上进行验证。LSTM 通过学习正常数据的时序模式, 并比较预测输出与实际观测值之间的差异来识别异常。为确保公平比较, LSTM 模型与 DFMT-Net 的保持一致, 输入序列的每个时间步包含 12 维特征, 3 层堆叠的 LSTM 中每层包含 128 个隐藏单元, 下游网络

表3 不同模型的性能对比

模型	异常检测			异常诊断			异常定位		
	F1 分数	准确率	均方误差	F1 分数	准确率	均方误差	F1 分数	准确率	均方误差
OCSVM	0.44	0.43	—	—	—	—	—	—	—
XGBoost	0.67	0.74	—	0.56	0.62	—	0.86	0.88	—
LSTM	0.87	0.86	0.005 7	0.78	0.79	0.363 1	0.75	0.71	0.373 7
DFMT-Net	<b>0.99</b>	<b>0.99</b>	<b>0.003 1</b>	<b>0.99</b>	<b>0.98</b>	<b>0.089 3</b>	<b>0.96</b>	<b>0.96</b>	<b>0.116 8</b>

模型保持不变。训练数据全部为正常工况数据，测试数据中包含异常样本。

表3展示了上述模型在3个任务中的性能表现。可以看出，DFMT-Net在各项任务中均显著优于现有模型相比传统机器学习与深度学习模型，DFMT-Net在F1分数上取得了更优结果。在异常检测任务中，F1分数相比XGBoost提升了47.76%，相比LSTM提升了13.79%，最终达到0.99；此外，准确率同样达到了0.99，在所有对比模型中最高。

图14展示了各模型的具体准确率、精确率、召回率和F1分数。从图中可以看出，传统的无监督学习模型在面对自由空间光通信信道中不断变化的条件时，异常检测能力较弱，常导致大量误判。相比之下，XGBoost与LSTM等有监督学习模型，依托深度特征拟合能力，在假阳性与假阴性之间取得了更好的平衡。

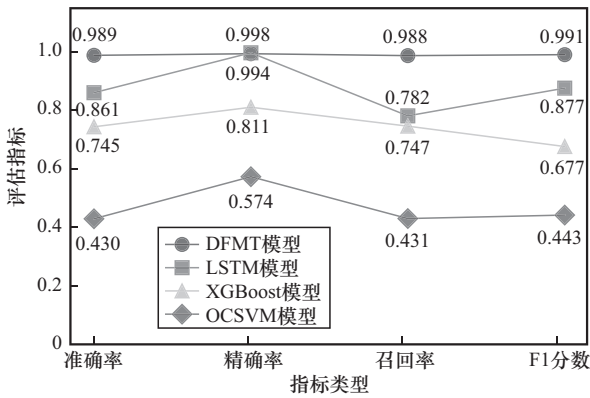


图14 DFMT-Net与传统模型的性能比较

在异常诊断与定位任务中，本文根据模型目标、网络模型及损失函数，对LSTM和XGBoost进行了进一步评估。结果表明，在异常诊断任务中，LSTM的F1分数为0.78，优于XGBoost的0.56；在异常定位任务中，XGBoost的F1分数达到0.86，优于LSTM的0.75。而DFMT-Net在两项任务中分

别取得了0.99和0.96的F1分数，分别提升了26.92%与11.63%，展现出显著优势。此外，本文还比较了各模型的推理时间。实验在一台配备Intel Xeon@2.20 GHz（2核4线程、56 MB三级缓存、32 GB内存）的服务器上进行。其中，LSTM与DFMT-Net均通过Tesla P100-PCIE-16 GB GPU加速运行。如表4所示，由于网络模型更深，DFMT-Net的推理时间略高于其他模型。值得注意的是，OCSVM在处理长序列且数据分布复杂的情况下，会生成大量支持向量，从而导致预测过程较慢。

表4 不同模型的推理时间

模型	推理时间 (3 232 s用例) /s	参数量	FLOPS
OCSVM	341.645 7 ± 2.555 0	—	—
XGBOOST	0.284 6 ± 0.071 1	14 400	315 0
LSTM	3.113 9 ± 0.007 0	412 696	35.8×10 <sup>9</sup>
DFMT-Net	<b>11.667 2 ± 0.006 1</b>	<b>997 472</b>	<b>17.6×10<sup>9</sup></b>

### 4 结束语

本文提出了一种基于深度学习的异常检测、分类与定位框架DFMT-Net来解决传统模型在应对FSO信道波动方面的局限性，本文引入了一种新颖的算法，将自注意力机制与先进的特征提取技术相结合。通过共享骨干网络增强了各任务之间的关联性，实现了对FSO信号数据中不同强度的大气湍流、指向误差以及遮挡等多源异构异常的精准分类与遮挡异常下的定位。

该框架利用重构误差和多路下游网络，在性能上取得了显著提升。实验结果表明，DFMT-Net的F1分数显著优于其他模型，相比XGBoost提升了47.76%，相比LSTM提升了13.79%，最终达到了0.99的F1分数。在异常诊断方面，模型的准确率达到了0.99，展现出极强的有效性与综合性能。在


异常定位任务中, 本文通过在通信链路上不同位置放置障碍物进行验证, 模型定位精度达到 0.961。综上所述, DFMT-Net 在特征提取、异常检测与定位任务中表现出色, 为未来 FSO 系统中的异常检测提供了稳健可靠的解决方案。

### 参考文献:

- [1] IMRAN M A, ZENNARO M, POPOOLA O R, et al. Exploring the boundaries of connected systems: communications for hard-to-reach areas and extreme conditions[J]. *Proceedings of the IEEE*, 2024, 112(7): 912-945.
- [2] ALWIS C D, KALLA A, PHAM Q V, et al. Survey on 6G frontiers: trends, applications, requirements, technologies and future research[J]. *IEEE Open Journal of the Communications Society*, 2021, 2: 836-886.
- [3] HAYLE S T, HSU H Y, WANG C P, et al. High-speed FSO-5G wireless communication system with enhanced loss compensation using high-power EDFA[J]. *Scientific Reports*, 2025, 15: 379.
- [4] ZHANG R Z, HU N Z, ZHOU H B, et al. Turbulence-resilient pilot-assisted self-coherent free-space optical communications using automatic optoelectronic mixing of many modes[J]. *Nature Photonics*, 2021, 15(10): 743-750.
- [5] MILANIZADEH M, SEYEDINNAVADEH S, ZANETTO F, et al. Separating arbitrary free-space beams with an integrated photonic processor[J]. *Light: Science & Applications*, 2022, 11: 197.
- [6] NADEEM F, KVICERA V, AWAN M S, et al. Weather effects on hybrid FSO/RF communication link[J]. *IEEE Journal on Selected Areas in Communications*, 2009, 27(9): 1687-1697.
- [7] BOLUDA-RUIZ R, GARCÍA-ZAMBRANA A, CASTILLO-VÁZQUEZ B, et al. Secure communication for FSO links in the presence of eavesdropper with generic location and orientation[J]. *Optics Express*, 2019, 27(23): 34211-34229.
- [8] EGHBAL M, ABOUEI J. Security enhancement in free-space optics using acousto-optic deflectors[J]. *Journal of Optical Communications and Networking*, 2014, 6(8): 684-694.
- [9] KARTALOPOULOS S V. Security in advanced optical communication networks[C]//*Proceedings of the 2009 IEEE International Conference on Communications*. Piscataway: IEEE Press, 2009: 1-5.
- [10] HUANG H Z, CHEN J, CHEN H S, et al. Secure free-space optical communication via amplified spontaneous emission (ASE) [C]//*Proceedings of the 2020 Optical Fiber Communications Conference and Exhibition (OFC)*. Piscataway: IEEE Press, 2020: 1-3.
- [11] KITAYAMA K I, SASAKI M, ARAKI S, et al. Security in photonic networks: threats and security enhancement[J]. *Journal of Lightwave Technology*, 2011, 29(21): 3210-3222.
- [12] PAUL P, BHATNAGAR M R. Jamming threats in free-space optics[J]. *IEEE Communications Magazine*, 2022, 60(12): 104-108.
- [13] LIU J W, ZHU H W, LIU Y X, et al. Anomaly detection for time series using temporal convolutional networks and Gaussian mixture model[J]. *Journal of Physics: Conference Series*, 2019, 1187(4): 042111.
- [14] WANG D S, SONG Y C, LI J, et al. Data-driven optical fiber channel modeling: a deep learning approach[J]. *Journal of Lightwave Technology*, 2020, 38(17): 4730-4743.
- [15] CHEN W B, ZHANG M, WANG D D, et al. Deep learning-based channel modeling for free space optical communications[J]. *Journal of Lightwave Technology*, 2023, 41(1): 183-198.
- [16] AL-AMODI A, MASOOD M, KHAN M Z M. Underwater wireless optical communication channel characterization using machine learning techniques[C]//*Proceedings of the 2022 IEEE 7th Optoelectronics Global Conference (OGC)*. Piscataway: IEEE Press, 2022: 50-54.
- [17] LIU X, ZHANG J, ZHU M, et al. Autoencoder learning of nonlinear constellation shape for fiber-wireless convergence system[C]//*Proceedings of the 2023 Optical Fiber Communications Conference and Exhibition (OFC)*. Piscataway: IEEE Press, 2023: 1-3.
- [18] LI Z Y, HUANG C L, JIA J L, et al. Deep learning-based end-to-end bit-wise autoencoder for G-band fiber-terahertz integrated DFT-S-OFDM communication system[C]//*Proceedings of the 2023 Optical Fiber Communications Conference and Exhibition (OFC)*. Piscataway: IEEE Press, 2023: 1-3.
- [19] JIN R Z, WEI Y, ZHANG J W, et al. Neural-network-based end-to-end learning for adaptive optimization of two-dimensional signal generation in UVLC systems[J]. *Optics Express*, 2024, 32(4): 6309-6328.
- [20] LI Z Y, DONG B Y, LI G Q, et al. Attention-assisted autoencoder neural network for end-to-end optimization of multi-access fiber-terahertz communication systems[J]. *Journal of Optical Communications and Networking*, 2023, 15(9): 711-725.
- [21] YAO L, ZHANG H Y, CHEN C X, et al. MPT-Transformer based post equalizer utilized in underwater visible light communication system[C]//*Proceedings of the 2023 Opto-Electronics and Communications Conference (OECC)*. Piscataway: IEEE Press, 2023: 1-4.
- [22] ZHOU Y T, ZHANG J W, LU C, et al. Low-complexity frequency-domain nonlinear equalizer with absolute operation for underwater wireless optical communications[J]. *Optics Express*, 2023, 31(14): 23086-23094.
- [23] GONG X X, LEI Y, ZHANG Q H, et al. Machine-learning-based optical spectrum feature analysis for DoS attack detection in IP over optical networks[J]. *Optics Express*, 2024, 32(3): 3793-3803.
- [24] SONG H K, LIN R, LI Y J, et al. Machine-learning-based method for fiber-bending eavesdropping detection[J]. *Optics Letters*, 2023, 48(12): 3183-3186.

- [25] LIU S Q, KONG J W, PAN X Q, et al. Highly-efficient and automatic spectrum inspection based on AutoEncoder and semi-supervised learning for anomaly detection in EONs[J]. *Journal of Lightwave Technology*, 2021, 39(5): 1243-1254.
- [26] ABDELLI K, GRIEBER H, EHRLE P, et al. Reflective fiber fault detection and characterization using long short-term memory[J]. *Journal of Optical Communications and Networking*, 2021, 13(10): 32-41.
- [27] ABDELLI K, CHO J Y, AZENDORF F, et al. Machine-learning-based anomaly detection in optical fiber monitoring[J]. *Journal of Optical Communications and Networking*, 2022, 14(5): 365-375.
- [28] ALLOGBA S, YAMÉOGO B L M, TREMBLAY C. Extraction and early detection of anomalies in lightpath SNR using machine learning models[J]. *Journal of Lightwave Technology*, 2022, 40(7): 1864-1872.
- [29] ABDELLI K, GRIEER H, PACHNICKE S. A machine learning-based framework for predictive maintenance of semiconductor laser for optical communication[J]. *Journal of Lightwave Technology*, 2022, 40(14): 4698-4708.
- [30] SHU L, YU Z M, WAN Z Q, et al. Adaptation mechanism for digital spectrum-based soft failure identification[C]//*Proceedings of the 14th Pacific Rim Conference on Lasers and Electro-Optics (CLEO PR 2020)*. Piscataway: IEEE Press, 2020: 1-5.
- [31] YANG H, WAN Y, YAO Q Y, et al. Anomaly prediction with hybrid supervised/unsupervised deep learning for elastic optical networks: a multi-index correlative approach[J]. *Journal of Lightwave Technology*, 2022, 40(14): 4502-4513.
- [32] ZHANG C Y, ZHANG M, LIU S L, et al. Covert fault detection with imbalanced data using an improved autoencoder for optical networks[J]. *Journal of Optical Communications and Networking*, 2023, 15(11): 913-924.
- [33] LI Y L, HUA N, LI J D, et al. Optical spectrum feature analysis and recognition for optical network security with machine learning[J]. *Optics Express*, 2019, 27(17): 24808-24827.
- [34] YU C L, WANG H Y, KE C J, et al. Multi-task learning convolutional neural network and optical spectrums enabled optical performance monitoring[J]. *IEEE Photonics Journal*, 2022, 14(2): 7217808.
- [35] AL-HABASH M A. Mathematical model for the irradiance probability density function of a laser beam propagating through turbulent media[J]. *Optical Engineering*, 2001, 40(8): 1554.
- [36] YANG F, CHENG J L, TSIFTSIS T A. Free-space optical communication with nonzero boresight pointing errors[J]. *IEEE Transactions on Communications*, 2014, 62(2): 713-725.
- [37] ZHOU H Y, ZHANG S H, PENG J Q, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2021, 35(12): 11106-11115.
- [38] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//*Proceedings of the 31st International Conference on Neural Information Processing System*. Massachusetts: MIT Press, 2017: 6000-6010.

## [作者简介]



宋嵩 (1992-), 男, 辽宁大连人, 博士, 重庆邮电大学讲师、硕士生导师, 主要研究方向为无线光通信、人工智能等。



吴廷伟 (1990-), 男, 重庆人, 博士, 重庆邮电大学讲师、硕士生导师, 主要研究方向为无线光通信、安全通信等。



赵伦 (1987-), 男, 湖北孝感人, 博士, 重庆邮电大学讲师、硕士生导师, 主要研究方向为无线光通信、毫米波通信等。



贾家庆 (2000-), 男, 重庆人, 重庆邮电大学硕士生, 主要研究方向为自由空间光通信、机器学习等。



郭磊 (1980-), 男, 四川眉州人, 博士, 重庆邮电大学教授、博士生导师, 主要研究方向为网络优化、网络通信、光网络等。