

引用本文:沈诗泽,杨林峰,张振荣,等.基于深度学习的双流特征融合光通信误码率预测[J].光通信技术,2026,50(3):17-21.

基于深度学习的双流特征融合光通信误码率预测

沈诗泽,杨林峰*,张振荣,禹钧译,杨 宰

(广西大学 计算机与电子信息学院,南宁 530004)

摘要:针对光通信系统误码率(BER)预测中传统模型的局限性与数据驱动方法信息利用不充分的问题,提出一种基于深度学习的双流特征融合光通信 BER 预测网络(DF-BERNet)。该网络并行处理 2 路特征:一是从原始物理参数中提取全局特征;二是通过快速傅里叶变换(FFT)构造局部工程化特征。2 路特征经拼接融合后,由多层感知机(MLP)进行回归预测。实验结果表明:相较于基准 MLP 模型($R^2=0.936$),DF-BERNet 的预测决定系数 R^2 提升至 0.985。该网络通过整合宏观与局部互补信息,显著提升了 BER 预测的准确性与鲁棒性。

关键词:光通信;误码率预测;深度学习;双流特征融合;双流网络

中图分类号:TN256 文献标志码:A 文章编号:1002-5561(2026)03-0017-05

DOI:10.13921/j.cnki.issn1002-5561.2026.03.003

Double stream feature fusion optical communication bit error rate prediction based on deep learning

SHEN Shize, YANG Linfeng*, ZHANG Zhenrong, YU Junyi, YANG Zai

(School of Computer and Information Engineering, Guangxi University, Nanning 530004, China)

Abstract: To address the limitations of traditional models and the insufficient information utilization of data-driven methods in bit error rate (BER) prediction for optical communication systems, a dual-stream feature fusion optical communication BER prediction network based on deep learning, termed DF-BERNet, is proposed. This network processes two feature streams in parallel: one extracts global features from raw physical parameters, and the other constructs local engineered features via fast Fourier transform (FFT). The two feature streams are concatenated and fused, and then fed into a multilayer perceptron (MLP) for regression prediction. Experimental results demonstrate that compared to the baseline MLP model ($R^2=0.936$), DF-BERNet achieves a coefficient of determination R^2 of DF-BERNet has been improved to 0.985. By integrating complementary macro-level and local information, the network significantly enhances the accuracy and robustness of BER prediction.

Key words: optical communication, bit error rate prediction, deep learning, dual stream feature fusion, dual stream network

0 引言

光纤通信网络是信息社会的重要基石,其传输性能的精准监测直接关系到网络的稳定运行。误码率(BER)作为衡量光网络传输质量的关键指标^[1-2],其水

平受衰减、色散、非线性效应、偏振模色散等多种物理因素共同影响。这些损伤因素导致信号失真,并最终决定系统 BER。因此,BER 预测是光网络性能监控的核心任务。


现有的 BER 预测方法主要分为传统解析方法与数据驱动方法两大类。传统解析方法以物理信道模型为基础,通常在加性高斯白噪声(AWGN)假设下开展分析。对于开关键控(OOK)等典型调制方式,BER 与 Q 因子满足特定关系,其中 Q 因子量化了接收信号的信噪比^[3]。尽管理想条件下此类模型可提供理论支撑,但在实际传输环境中,色散、非线性干扰、器件非理想特性等多因素耦合造成的复杂动态损伤难以被精确表征^[4]。模型与实际物理传输过程存在的固有偏

收稿日期:2025-06-03。

基金项目:广西重点研发计划项目(桂科 AB23075155)资助;桂科 AB25069071)资助。

作者简介:沈诗泽(2000—),男,硕士研究生,现就读于广西大学计算机与电子信息学院计算机技术专业,主要研究方向为光通信与机器学习的交叉应用,具体包括参数预测与系统优化。

*通信作者:杨林峰(1979—),男,博士,教授,主要从事最优化算法、机器学习理论与算法方面的研究。



沈诗泽,杨林峰,张振荣,等:基于深度学习的双流特征融合光通信误码率预测

差,导致传统解析与半解析方法在面向现代高速、长距离光通信系统时,准确性与鲁棒性存在明显局限。随着人工智能技术的发展,数据驱动方法为光通信性能预测提供了新路径^[5]。早期研究采用支持向量机、决策树、随机森林等传统机器学习算法,但均依赖人工特征工程,表征能力有限,难以充分拟合复杂非线性关系。近年来,深度学习凭借优异的非线性建模与自动特征提取能力,展现出巨大潜力。例如,卷积神经网络(CNN)这类模型在光性能监测中取得一定成效^[6];多层感知机(MLP)已被用于数字预失真以补偿非线性损伤^[7],并在现场可编程门阵列(FPGA)上验证了其在处理光信号非线性损伤方面的可行性。部分研究尝试融合传统统计模型与深度学习,以提升复杂信道下的模型鲁棒性^[8]。然而,当前数据驱动方法仍存在不足:多数研究采用单一信息输入,特征提取方式相对简单,未充分利用多源数据的互补特性。现有方法往往无法兼顾原始物理参数所蕴含的系统全局宏观信息,以及经变换后反映信号局部动态结构的工程化特征。这种信息利用的不充分性,限制了预测精度的进一步提升。为此,本文提出一种基于深度学习的双流特征融合光通信误码率预测网络(下文简称DF-BERNet)。该网络通过并行分支融合原始物理参数表征与工程化特征,协同学习系统宏观状态与信号局部动态信息,有效提升BER预测精度与泛化能力^[9]。

1 DF-BERNet

1.1 模型总体架构

本文提出的DF-BERNet模型结构如图1所示。该模型联合利用原始信号数据与物理特征信息,从互补视角开展学习建模,可有效捕捉信号时频特性与传输系统物理属性,实现BER的高精度预测。DF-BERNet的核心为双流特征融合网络,分别处理2路不同来源的输入数据:

1)全局物理参数直接表征分支:直接接收描述光通信链路状态的原始多维物理参数作为输入。这些参数是在实验或仿真中直接测定或设定的宏观配置信息,旨在反映系统整体状态对BER的影响。

2)工程化物理特征提取分支:依据物理机制提取通信参数特征。对于每一组实验参数,本模型将其视为一个数值序列,从中提取时域统计特征和基于快速傅里叶变换(FFT)的频域统计特征。此举旨在挖掘参数间的内在交互规律及局部动态结构信息。

这2路特征随后进入双流特征融合网络,通过拼




图1 DF-BERNet模型结构图

接融合后由MLP进行回归预测,最终输出BER预测值 y 。通过这种设计,模型可同时利用系统级配置与信号级畸变细节,克服单一特征源的局限性。

1.2 全局物理参数直接表征分支

DF-BERNet的第一个核心组件是全局物理参数表征分支。该分支的设计目标是:从描述光通信系统整体配置与宏观状态的原始多维物理参数中,建立这些参数与BER之间的映射关系。

该分支首先对原始物理参数集执行标准化处理,以消除不同物理量纲带来的数值差异;随后,通过主成分分析(PCA)实现特征降维与去相关,得到PCA特征 T 。该过程可有效凝练原始参数的核心信息,在最大程度保留数据内在差异性的同时,获取高代表性低维特征,为后续MLP网络提供易于学习的特征基础。

1.3 工程化物理特征提取分支

为进一步挖掘原始物理参数中与BER相关的潜在关联模式,DF-BERNet设计了工程化物理特征提取分支。与全局参数表征分支直接处理原始参数不同,该分支以原始物理参数集 X_{raw} 中单次实验对应的完整参数组合为单元,通过数学变换与统计计算构建工程化特征 F 。

具体而言,对每一参数组合向量,分别计算均值、标准差、偏度及峰度,以刻画参数分布与离散特性;同时对其执行FFT并提取频谱统计特征。此处,FFT并非用于解析物理频率分量,而是以数据驱动方式完成基函数展开,其系数统计分布可反映参数间的内在交互规律,为模型提供与原始参数空间互补的特征视角。

1.4 双流特征融合网络

本文所设计的双流特征融合网络具备天然互补性,二者分别从不同维度刻画光通信系统损伤对BER

的影响机制。

全局物理参数直接表征分支处理系统宏观配置原始多维参数,可明确系统工作点,提供与系统设计强相关的全局背景信息。但光纤传输中的瞬时畸变、色散累积、非线性相位噪声等复杂动态过程,难以通过静态宏观参数完整表达。工程化物理特征提取分支针对上述不足,对原始参数(尤其时变信号与信道响应参数)进行FFT频域变换,所构建的工程特征 F 能够有效揭示数据内在物理结构,如频率分量畸变、噪声频谱分布、非线性相互作用谱线等局部精细信息,弥补了原始时域/宏观参数的表达局限。

简言之,全局分支刻画系统配置,工程特征分支表征信号动态变化。2路特征的融合并非简单信息叠加,而是实现系统全局配置信息与信号局部动态损伤特征的深度关联,使模型可同时利用系统级配置与信号级畸变细节,更全面地掌握致BER劣化的多源物理机理,有效避免单一特征视角带来的关键损伤信息丢失,进而提升预测精度与复杂损伤环境下的鲁棒性^[10-12]。

本文采用特征拼接实现融合,该方式简洁高效且可无损保留2路信息,为后续网络学习特征交互提供基础^[13]。对每个样本,将 T 与 F 沿特征维度连接,得到更丰富的融合特征向量如式(1)所示。

$$h_{\text{fused}} = \text{concat}(T, F) \quad (1)$$

然后,这个拼接得到的融合特征向量 h_{fused} 被送入一个专门的融合预测网络,记为 f_{predict} 。该网络由一个MLP层构成。此网络的核心职责是对前文高度整合的特征信息进行进一步的非线性变换、信息提炼,并最终将其精确地映射到对BER的连续值预测,如式(2)所示。

$$\hat{y}_{\text{BER}} = f_{\text{predict}}(h_{\text{fused}}; \Theta_{\text{predict}}) \quad (2)$$

式中: $\hat{y}_{\text{BER}}$ 为模型预测得到的BER值, Θ_{predict} 为网络训练得到的模型参数。

DF-BERNet采用端到端训练,以均方误差(MSE)为损失函数 L_{MSE} ,其表达式为

$$L_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_{\text{BER}, i})^2 \quad (3)$$

式中: N 为样本总数, y_i 为第 i 个样本的真实BER值。

DF-BERNet通过高效的梯度下降优化算法最小化损失函数 L_{MSE} ,从而全面学习从2路信息源中提取关键特征、智能融合多源信息,并最终实现对光通信系统BER的精确预测。这种双流特征融合网络的设计,充分利用了不同特征表示的互补优势,克服单一特征

带来的局限性,从而在复杂的实际应用场景中展现出更优的性能。

2 实验与结果分析

为验证DF-BERNet的有效性与先进性,本文从数据集、评价指标、对比方案、消融实验、泛化性能等方面开展系统性实验,全面分析模型的预测精度与鲁棒性。

2.1 数据集采集

实验采用Kaggle平台公开的OptiCom Signal Quality Dataset数据集,所有信号数据均经标准化预处理,保证模型训练过程的一致性与稳定性。依据本文设计的特征提取方案,从原始数据中提取时域统计特征与FFT频域特征,充分挖掘数据的统计特性与频谱规律,为BER高精度预测提供有效信息支撑。

2.2 融合策略对比实验设计

DF-BERNet的核心在于双流特征融合网络,而特征拼接融合策略是该网络中实现多源信息整合的关键融合策略。为验证该拼接策略相较于其他常见融合方式的优势,本文将其与加权求和、注意力机制及门控融合3种典型融合策略进行对比实验。以MSE、均方根误差(RMSE)、决定系数 R^2 为评价指标,结果如表1所示。可以看出,本文采用的特征拼接融合策略各项指标均最优。这是因为拼接操作能够无损保留双流分支提取的多源互补信息,完整维系了宏观物理参数与微观频域统计特征间的内在关联;相比之下,加权或门控融合往往涉及线性组合或非线性映射,易引发特征压缩或关键信息丢失。拼接融合有效规避了上述局限,促使网络充分学习不同维度特征间的深层耦合机制,从而显著提升了BER预测精度与模型鲁棒性。

表1 融合策略对比实验结果

融合策略	MSE	RMSE	R^2
加权求和	1.60×10^{-3}	0.040	0.961
注意力机制	2.41×10^{-3}	0.049	0.953
门控融合	3.39×10^{-3}	0.058	0.933
特征拼接融合	0.75×10^{-3}	0.027	0.985

2.3 消融实验

为定量评估DF-BERNet对BER的预测性能,本文设计了2组对照消融实验:仅以原始物理参数为输入

沈诗泽,杨林峰,张振荣,等:基于深度学习的双流特征融合光通信误码率预测

的MLP模型(原始数据组)和本文构造的工程化物理特征为输入的MLP模型(特征数据组)。所有模型均在相同数据集划分、超参数配置及训练策略下进行优化与评估,采用MSE、RMSE和 R^2 作为统一评价指标,结果如表2所示。可以看出,本文提出的DF-BERNet(双流特征融合组)展现出最优的预测性能:MSE降至 0.75×10^{-3} ,RMSE为0.027, R^2 达0.985。定量对比分析显示,相较于原始数据组,双流特征融合组的MSE相对降低76.78%;相较于特征数据组,双流特征融合组的MSE亦降低66.06%。上述结果充分验证了双流特征融合网络的有效性:通过全局物理参数表征与工程化变换特征的协同融合,模型能够充分利用两类特征的互补优势,增强对复杂传输损伤的联合表征能力,从而显著提升BER预测的精度与拟合优度。

表2 消融实验结果

实验组	MSE	RMSE	R^2
原始数据	3.23×10^{-3}	0.056	0.936
特征数据	2.21×10^{-3}	0.047	0.956
双流特征融合	0.75×10^{-3}	0.027	0.985

2.4 对比实验

为全面评估本文提出的DF-BERNet在光通信系统BER预测任务中的性能,将其与多种经典的机器学习回归算法及一个标准的MLP模型进行了横向对比。基准对比方法包括随机森林回归(RFR)、支持向量回归(SVR)以及梯度提升树(GBT),实验结果如表3所示。可以看出,本文所提DF-BERNet在各项评价指标中均取得最优结果,预测性能显著优于其他传统机器学习算法。上述结果验证了DF-BERNet的双流特征融合网络的有效性:一方面,以MLP为代表的深度学习模型凭借多层非线性映射结构,具备更强的复杂关系拟合与隐式特征挖掘能力;另一方面,DF-BERNet通过双分支并行提取全局物理参数与工程化频域特

表3 对比实验结果

模型类型	MSE	RMSE	R^2
RFR	6.05×10^{-3}	0.077	0.881
SVR	4.29×10^{-3}	0.065	0.915
GBT	6.73×10^{-3}	0.082	0.867
MLP	3.23×10^{-3}	0.056	0.936
DF-BERNet	0.75×10^{-3}	0.027	0.985

征,并采用无损拼接策略实现多源信息深度整合,可从系统配置与信号动态双视角协同捕捉影响BER的关键物理机制。这种互补特征的联合表征与端到端协同学习,有效克服了单一模型或单一特征源的信息表达局限,从而在复杂传输损伤场景下实现了BER预测精度的实质性突破。

2.5 融合特征的模型泛化性分析

为进一步验证DF-BERNet所构建的双流特征融合网络(即全局物理参数表征与工程化特征提取)及其拼接融合策略的普适应用价值与泛化能力,规避性能提升仅适配单一网络结构的偶然性问题,本文将优化后的融合特征向量迁移至多种经典机器学习回归模型中进行对比测试,结果如表4所示。

表4 融合策略的泛化实验结果

模型类型	MSE	RMSE	R^2
RFR	6.05×10^{-3}	0.077	0.881
SVR	4.29×10^{-3}	0.065	0.915
GBT	6.73×10^{-3}	0.082	0.867
RFR(融合)	3.58×10^{-3}	0.059	0.929
SVR(融合)	1.54×10^{-3}	0.039	0.969
GBT(融合)	5.46×10^{-3}	0.073	0.892

由表4数据可知,SVR模型引入融合特征后性能提升幅度最为显著, R^2 由0.915提升至0.969,在全部传统机器学习对比模型中综合预测效果最优。GBT模型引入融合特征后预测性能同样稳步改善, R^2 由0.867提升至0.892,整体提升幅度略低于RFR与SVR模型。实验结果表明,即便针对GBT这类自带特征构建与自适应筛选能力的集成学习模型,本文所提双流特征融合网络仍可补充有效隐性关联特征,持续赋能模型提升BER预测综合精度,充分印证了模型良好的泛化适配能力。

2.6 基于不同模型的性能分析

本文DF-BERNet模型为基于MLP的双流特征融合预测网络,其收敛情况如图2所示。可以看出,在初始25轮迭代中,训练集与验证集的MSE均迅速下降,表明模型具备高效学习数据特征的能力。经过25~125轮的调整期后,模型自125轮起进入稳定收敛状态,此时训练集与验证集的MSE均维持在较低水平且变化平缓,两者之间差异稳定,充分证明了模型具有良好的拟合性能。




图2 基于MLP的DF-BERNet收敛曲线图

为验证双流特征融合网络的通用性,本文进一步在GBT和SVR模型上进行了泛化实验。实验结果表明,引入特征融合显著提升了传统机器学习模型的预测性能:对于GBT模型,特征融合帮助模型更高效地捕捉数据中的主要非线性规律,在减少收敛所需迭代次数的同时,将预测决定系数 R^2 从0.867提升至0.892;对于SVR模型,特征融合构建了更具线性可分性与结构化的信息空间,助力模型构建更优的回归超平面,使其 R^2 由0.915显著跃升至0.969。上述结果证实,本文提出的DF-BERNet具有高度的模型无关性,能有效赋能各类基线算法,弥补单一特征源的信息局限。

3 结束语

为解决光通信BER预测中多源信息融合不充分的问题,本文提出了DF-BERNet模型。通过构建全局物理参数与局部工程化特征的双流特征融合网络,有效捕捉了系统宏观状态与信号微观动态的互补信息。实验结果表明:DF-BERNet的 R^2 高达0.985,性能显著超越各类基准模型。同时,泛化实验证明该双流特征融合网络具备模型无关性,能普遍赋能SVR、随机森林等传统算法,验证了多视角特征工程的普适价值。

未来工作将聚焦于两点:一是在真实动态光网络环境中验证模型的实时性与泛化能力;二是开展模型

轻量化研究,以满足边缘侧低功耗部署需求,加速其工程化应用进程。

参考文献:

- [1] 杨恺. 基于深度学习的光纤通信高阶色散预测[J]. 光学技术, 2021, 47(6): 716-721.
- [2] 郭忠义, 龚超凡, 刘洪郡, 等. OAM 光通信技术研究进展[J]. 光电工程, 2020, 47(3): 190593-1-190593-34.
- [3] Proakis J, Salehi M. Digital communications[M]. 4th ed. New York: McGraw-Hill, 2001.
- [4] Agrawal G P. Fiber-optic communication systems[M]. New York: John Wiley & Sons, 2012.
- [5] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012, 25.
- [6] Thrane J, Wass J, Piels M, et al. Machine learning techniques for optical performance monitoring from directly detected PDM-QAM signals[J]. Journal of Lightwave Technology, 2016, 35(4): 868-875.
- [7] Faisal N K, Fan Qirui, Lu Chao, et al. Machine learning methods for optical communication systems and networks[M]. London: Academic Press, 2020: 921-978.
- [8] Hager C, Pfister H D. Physics-based deep learning for fiber-optic communication systems[J]. IEEE Journal on Selected Areas in Communications, 2020, 39(1): 280-294.
- [9] Shao C, Giacomidis E, Billah S M, et al. Machine learning in short-reach optical systems: a comprehensive survey[J]. Photonics, 2024, 11(7): 613.
- [10] Kim H, Kim J T, Shin S, et al. Prediction of run-off road crash severity in south Korea's highway through tree augmented naïve bayes learning[J]. Applied Sciences, 2022, 12(3): 1120.
- [11] Baltruš-Aitis T, Ahuja C, Morency L P. Multimodal machine learning: a survey and taxonomy[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 41(2): 423-443.
- [12] Pérez-Rúa J M, Vielzeuf V, Pateux S, et al. Mfas: multimodal fusion architecture search[C]//IEEE. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 6966-6975.
- [13] Ramachandram D, Taylor G W. Deep multimodal learning: a survey on recent advances and trends[J]. IEEE Signal Processing Magazine, 2017, 34(6): 96-108.