光电技术及应用

DOI：10.16818/j.issn1001－5868.20250925003

基于MHA-1DMini-Xception的光纤复合架空地线覆冰识别

杨润平[1*]，苏润梅[1]，袁　隆[1]，陈　思[2]，张竟超[1]，李国良[1]，尚秋峰[3]，姚国珍[3]

（1. 内蒙古电力（集团）有限责任公司 内蒙古超高压供电分公司，呼和浩特 010000；2. 内蒙古电力（集团）有限责任公司，呼和浩特 010000；3. 华北电力大学 电子与通信工程系，河北 保定 071003）

摘　要： 基于深度学习的相位敏感光时域反射计（Φ-OTDR）智能信号处理技术已成为研究热点。针对光纤复合架空地线（OPGW）覆冰监测应用，文章提出一种改进的MHA-1DMini-Xception深度学习网络模型。该模型通过改进Mini-Xception网络中的深度可分离卷积模块，使其在参数较少的情况下仍保持模型优良性能，且可有效提取一维时序信号特征。同时引入多头注意力机制，通过并行计算允许模型在不同的表示子空间内学习特征信息，从而增强模型的表达能力，提升网络的鲁棒性。将Φ-OTDR采集的OPGW覆冰振动信号划分为无覆冰、一级覆冰和二级覆冰三类数据，使用MHA-1DMini-Xception模型对覆冰数据集进行分类识别。实验结果表明，模型对测试集样本的识别准确率达到了97.47%，性能优于CNN模型和Mini-Xception模型。所提方法为光纤振动信号的分类识别提供了有益参考，具有较高的应用价值。

关键词： Φ-OTDR；Mini-Xception网络；多头注意力机制；OPGW；覆冰监测

中图分类号： TN911.6　**文章编号：** 1001－5868(2025)06－1088－07

Optical-Fiber Composite Overhead Ground Wire Icing Identification Method Based on MHA-1DMini-Xception

YANG Runping[1], SU Runmei[1], YUAN Long[1], CHEN Si[2], ZHANG Jingchao[1], LI Guoliang[1], SHANG Qiufeng[3], YAO Guozhen[3]

(1. Inner Mongolia Ultra High Voltage Power Supply Branch, Inner Mongolia Electric Power (Group) Co. Ltd., Hohhot 010000, CHN; 2. Inner Mongolia Electric Power (Group) Co. Ltd., Hohhot 010000, CHN; 3. Department of Electronics and Communication Engineering, North China Electric Power University, Baoding 071003, CHN)

Abstract: Phase-sensitive optical time-domain reflectometer (Φ-OTDR) intelligent signal-processing technology based on deep learning has been extensively investigated. In this study, the MHA-1DMini-Xception deep-learning network model is proposed for optical-fiber composite overhead ground wire (OPGW) icing monitoring and processing. By improving the deep separable convolution module of the Mini-Xception network, the model maintains excellent performance with fewer parameters and effectively extracts one-dimensional time-series signal features. Simultaneously, a multi-head attention mechanism is introduced to allow the model to learn feature information in different representation subspaces through parallel computing, thus enhancing the expression ability of the model and improving the robustness of the network. The OPGW icing vibration signal obtained by a

收稿日期：2025－09－25.

基金项目：内蒙古电力（集团）有限责任公司2023年科技项目（2023-5-25）.

* 通信作者：杨润平

Φ-OTDR is classified into three data categories, i. e., no icing, first-level icing, and second-stage icing. Additionally, the MHA-1DMini-Xception model is used to classify and identify the icing dataset, and the recognition accuracy of the samples in the test set is 97.47%, which is better than that afforded by a CNN model and the Mini-Xception model. This method provides a valuable reference for the classification and identification of optical-fiber vibration signals.

Key words: Φ-OTDR; Mini-Xception network; multihead attention mechanism; OPGW; transmission-line monitoring

0　引言

分布式光纤传感技术利用光纤作为传输媒介和传感单元，通过检测光纤中光信号参量的变化，实现对光纤沿线环境参量的连续分布式测量[1]。相位敏感型光时域反射计（Φ-OTDR）具有抗电磁干扰、灵敏度高等优势，能够精确定位光纤沿线的振动事件，并监测振动信号幅度、相位和频率等矢量信息，被广泛应用于输电线路监测、海底电缆、管道泄漏检测、周界安防等领域[2-7]。

覆冰作为一种频发的架空输电线路灾害，严重威胁着电力系统的安全运行[8]。Φ-OTDR利用光纤复合架空地线（OPGW）作为传感单元，结合振动信号识别方法，可以实现全天候、全线路运行状态的智能感知，在输电线路状态监测领域有着广泛的应用前景。

目前，在Φ-OTDR信号处理领域典型的分类识别方法以机器学习和深度学习为主。基于机器学习的识别方法对特征工程的依赖性较强，需要依据人工经验对信号提取特征，其识别效果高度依赖于特征选取的类别和数量，在处理复杂模式时泛化能力不足[9-10]。此外，传统机器学习模型在面对高维数据时经常表现不佳，且在处理大规模数据时计算效率较低，而深度学习网络具有自动特征提取和处理复杂数据的能力。深度学习通过多层神经网络能够学习更高层次的抽象特征，适用于一维时序、二维图像等复杂数据。其中，作为被广泛应用的深度学习模型，卷积神经网络（CNN）在光纤振动信号处理与分类识别领域的应用成为研究热点。2019年，Wu[11]等设计了一种可以自动提取一维振动信号特征的神经网络模型，并用SVM分类器取代CNN的Softmax层，并通过实验验证了该方法在识别准确率方面优于传统机器学习方法。2021年，Zhang[12]等提出一种1D-CNN的变种模型网络（DenseNet）实现了高效实时的在线处理，但该模型只提取了信号的局部结构信息，表达能力欠佳，影响识别性能。

Mini-Xception具有模型轻量化、较低计算复杂度、提取深层特征以提高识别准确率等优势，被广泛应用于图像分类领域。考虑到Φ-OTDR系统采集的光纤振动信号为一维时序信号，本文选择Mini-Xception为基本网络，提出了改进的Mini-Xception模型结构，即1DMini-Xception模型，旨在更好地适应一维时序信号。为提升模型在处理复杂场景中的表达能力，引入了多头注意力机制，构建了MHA-1DMini-Xception网络模型。对比分析通道注意力机制、局部注意力机制、多头注意力机制在1DMini-Xception模型下的性能，结果表明多头注意力机制效果最佳，识别准确率达到了97.46%。此外，还对CNN，Mini-Xception，MHA-1DMini-Xception三种深度学习模型在覆冰测试样本集上的识别效果进行对比分析，验证了所提方法有更加优异的识别性能。

1　MHA-1DMini-Xception原理

1.1　深度可分离卷积模块

深度可分离卷积[13]与传统卷积不同，其由深度卷积和逐点卷积共同构成，如图1所示。深度卷积在每个通道上独立执行卷积，从而有效提取空间特征；逐点卷积使用1×1卷积将这些特征进行汇聚，处理不同通道的特征。

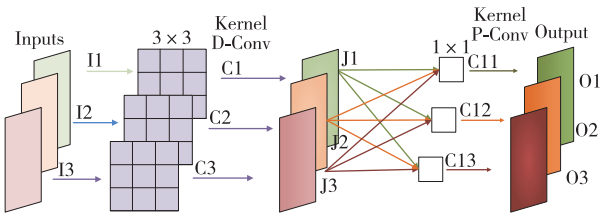


图1　深度可分离卷积结构示意图

深度可分离卷积通过减少训练参数和计算量，大幅提升模型的速度和效率。首先，模型对每个通

道进行独立的深度卷积操作，将输入数据与对应的卷积核卷积，实现对深度方向的卷积。随后，逐点卷积将这些深度卷积的结果汇聚，通过对所有通道的结果进行加和，生成最终输出。这种方法不仅可以降低计算复杂度，同时还保留了丰富的特征表达能力。

1.2 Mini-Xception模型

Mini-Xception为轻量级卷积神经网络，如图2所示。该网络放弃传统神经网络的全连接层，以深度可分离卷积替换传统的卷积层，显著缩短训练时间。该模型与传统的卷积神经网络的主要不同之处在于包含4个残差深度可分离卷积模块。首先将数据进行两次卷积和批处理化初步提取特征，接着使特征经过4个残差深度可分离卷积模块，获得更深层次的特征信息并加快网络收敛。然后，将深层次特征输入到全局平均池化层进行筛选，保留其重要特征信息。最后，通过Softmax激活函数输出类别概率分布实现分类识别。

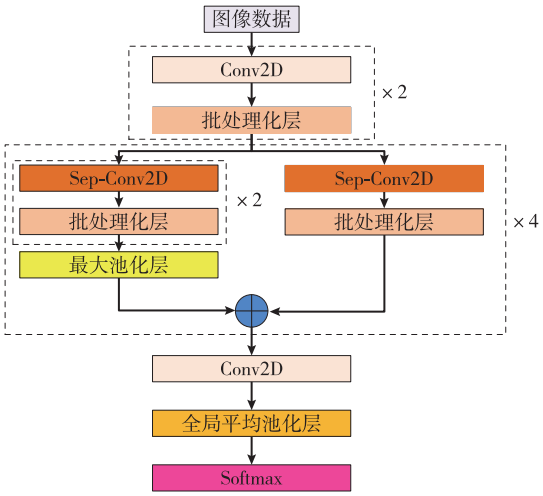
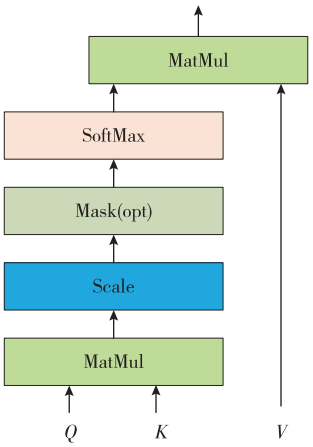


图2 Mini-Xception网络架构

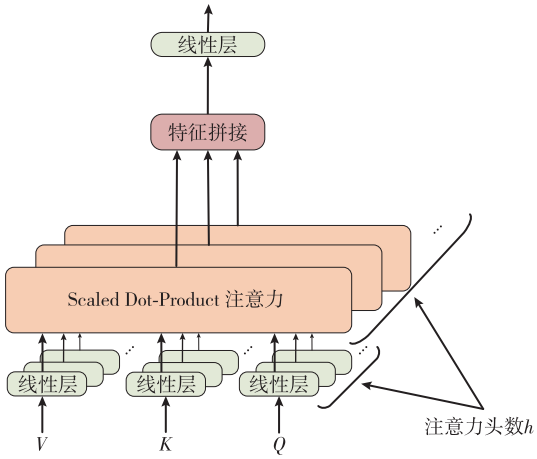
在Xception的基础上进行改进的Mini-Xception网络模型，减少了模型的网络层级，结构更加简单明了，从而提高了模型的泛化能力。尤其是Mini-Xception放弃了传统神经网络的全连接层，同时以深度可分离卷积替换传统卷积，显著缩短了训练时间。

1.3 多头注意力机制模块

多头注意力机制模块(MHA)[14]是深度学习中的关键技术。由于时序信号的数据点之间可能存在长距离的依赖关系，而传统神经网络在捕捉这些长距离依赖方面有一定难度。多头注意力机制模块通过自注意力机制能够有效捕捉长距离的关系，每个注意力头能够关注不同的时间步，从而更全面地理解时序数据的全局模式。此外，MHA模块能够从多个角度分析时序信号，并同时关注不同时间尺度的信息，有助于提取信号复杂的时序特征。如图3所示，h为注意力头的数量，W^O是用于最后线性变换的权重矩阵。



(a) Scaled Dot-Product注意力结构图



(b) 多头注意力机制示意图

图3 多头注意力机制模块

MHA模块首先将输入的当前处理的输入序列即查询(Query)、待匹配的输入序列即键(Key)和与键相关联的输出信息即值(Value)这三个矩阵映射到多个子空间，然后计算查询(Q_i)和键(K_i)之间的点积，通过一个缩放因子$\sqrt{d_k}$(其中d_k是键的维度)进行缩放得到注意力得分(AS)，如公式(1)所示。对得分应用Softmax函数以获得注意力权重(AW)，如公式(2)所示。将这些注意力权重应用于与键相关联的输出信息即值(V_i)，得到加权和作为每个头的输出(HO_i)，如公式(3)所示。最后将所有头的输出进行拼接(Concat)，然后通过一个线性变

换矩阵（W^O）将其映射回原始的维度（MHO），如公式（4）所示。

$$AS=\frac{Q_iK_i^{\mathrm{T}}}{\sqrt{d_k}} \tag{1}$$

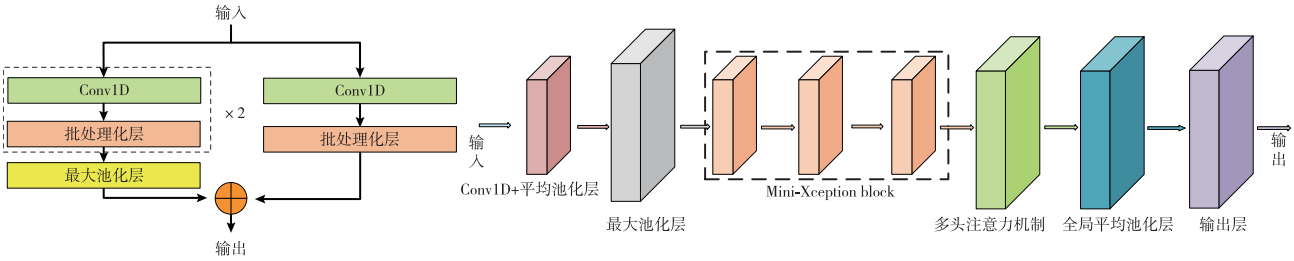
$$AW=\mathrm{Softmax}(AS) \tag{2}$$

$$HO_i=\mathrm{AW}\cdot V_i \tag{3}$$

$$MHO=\mathrm{Concat}(HO_1,\cdots,HO_h)W^O \tag{4}$$

1.4　MHA-1DMini-Xception 模型

目前 Mini-Xception 网络主要是针对二维图像数据，但该网络本身具有高效的计算性能，因其使用了深度可分离卷积，减少了参数数量和计算量，以及在处理特征时能够捕捉复杂的特征，并且其小型化设计也使得它在资源受限的环境中表现出色。因此，本文调整了模型结构，将深度可分离卷积模块改进为一维深度可分离卷积模块，以适应一维时序信号。为了克服模型无法充分提取一维时序信号特征、捕捉长距离数据点之间的依赖关系及关注不同时间尺度特征信息的问题，本文对 Mini-Xception 的卷积模块进行改进，如图 4（a）所示。引入多头注意力机制（MHA），旨在进一步提高模型的精度，如图 4（b）所示。



（a）Mini-Xception block 结构　　（b）MHA-1DMini-Xception 算法流程

图 4　MHA-1DMini-Xception 模型

2　覆冰监测系统与数据集构建

2.1　覆冰监测系统

在某变电站部署覆冰监测系统，如图 5 所示，并采集 Φ-OTDR 在不同类型覆冰工况下的光纤振动信号。采用 1 550 nm 波长的窄线宽激光器产生稳定连续的激光，通过耦合器以 9∶1 的比例输出探测光和本地光。探测光经过声光调制器进行频率调制，并通过掺铒光纤放大器放大，随后经光纤环形器进入 OPGW，返回的后向瑞利散射光（RBS）携带了环境扰动引起的光纤振动信息。RBS 经过环形器后与本地光在 3 dB 耦合器中拍频，拍频信号输入到平衡光电探测器被转换为电信号，再通过数据采集卡将数字信号传输到电脑中进行分析和处理。

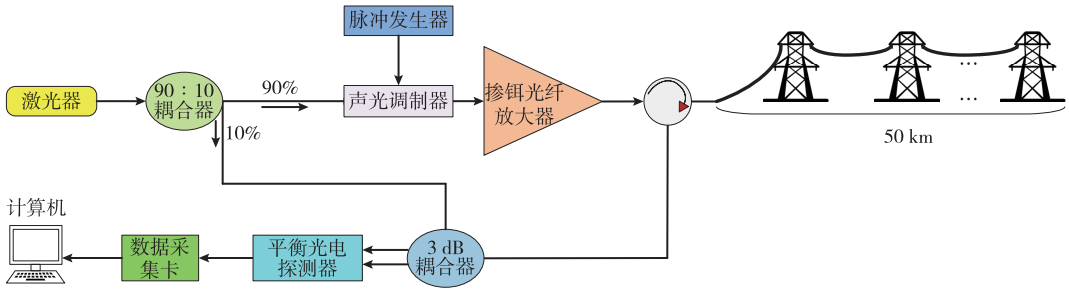


图 5　Φ-OTDR 系统组成框图

2.2　覆冰数据集制作

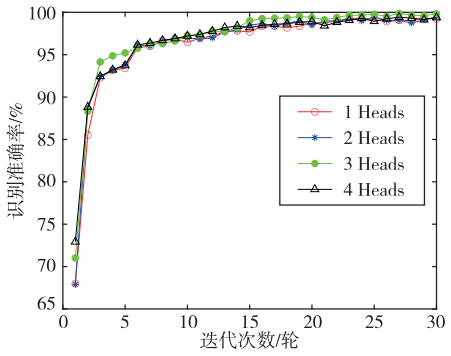
对 OPGW 覆冰情况下的光纤振动信号进行分类识别。OPGW 线路全长 50 km，其中站内光缆长度为 10 km，站外输电线路长 40 km。鉴于现场观测显示可知：2023 年 12 月 13 日输电线出现轻微覆冰，厚度为 0～5 mm；12 月 15 日因持续降雪，覆冰厚度增至 5～10 mm；12 月 26 日则无覆冰。为了提升模型泛化能力，采集 12 月 13 日、12 月 15 日和 12 月 26 日的 OPGW 振动数据，选取其中输电线路沿线的五个不同距离点数据：10.5 km，15 km，20 km，25 km 和 30 km，对一级覆冰（0～5 mm）、二级覆冰（5～10 mm）和无覆冰三种类别的现场实际数据进行分

类识别。通过上述样本数据划分方法，获取三种类别的数据样本数各为6 400组，且每类数据以8∶2的比例划分为训练集和测试集，并将事件类别标签设置为独热编码形式。另外在训练时将样本随机打乱，对训练集再以8∶2的比例划分为训练集和验证集，以保证模型能够得到充分训练。

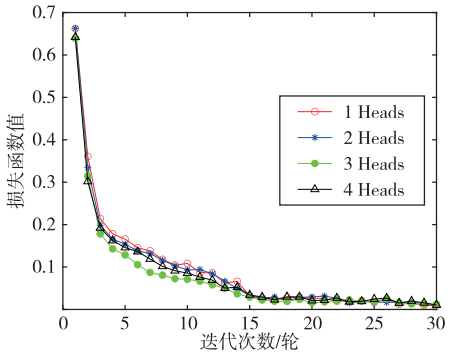
3 现场覆冰数据分析

3.1 多头注意力机制参数设置

多头注意力机制性能优劣由其头数决定，头数越多，模型越能更好提取信号特征。然而，头数过多会增加网络复杂度，导致算法运行时间过长。因此，本文使用图4所示的网络模型，采用1，2，3，4共四种注意力头数，分析头数对多头注意力机制性能的影响。其中，Mini-Xception block模块数统一为3，且各模块卷积核数量分别设置为8，16和32。卷积核大小设置为3，训练过程中batch size设置为500，最大训练次数epochs设置为30。不同头数模型的识别准确率与损失函数曲线对比如图6所示。由图6可知，随着迭代次数不断增加，各曲线均逐渐达到收敛状态，其中注意力头数为3的多头注意力机制识别准确率略高于其他模型，且其损失函数收敛速度也快于其他模型。因此，将MHA-1DMini-Xception模型的多头注意力机制头数设为3。



（a）多头注意力机制不同参数识别准确率曲线图

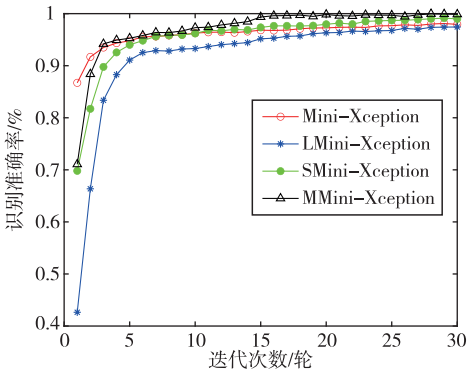


（b）多头注意力机制不同参数损失函数曲线图

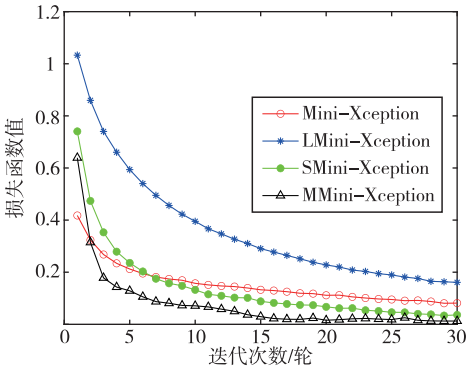
图6 多头注意力机制不同参数性能分析对比

3.2 多头注意力机制性能评估

将多种注意力机制与1DMini-Xception融合构建了MHA-1DMini-Xception模型。在1DMini-Xception基础上比较分析四种情况：无注意力机制（简称Mini）、局部注意力机制（简称LMini）、通道注意力机制[15]（简称SMini）、多头注意力机制（简称MMini）。四种情况下的模型参数与3.1节中最优模型参数保持相同。如图7和表1所示，当各模型训练曲线收敛时，较其他三种模型，MHA-1DMini-Xception模型覆冰等级的识别准确率变化更加稳定，模型训练时的损失函数的收敛速度更快，且该模型的识别准确率最高。



（a）训练集识别准确率曲线图



（b）训练集损失函数曲线图

图7 学习机制性能对比

表1 学习机制验证集模型性能评估

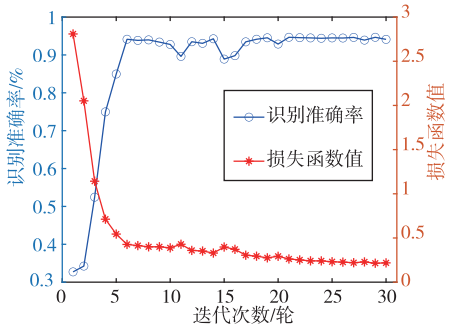
评价指标	Mini	LMini	SMini	MMini
识别准确率/%	96.20	96.06	97.08	97.46
损失函数	0.161 3	0.179 0	0.098 4	0.090 4

3.3 MHA-1DMini-Xception模型性能评估

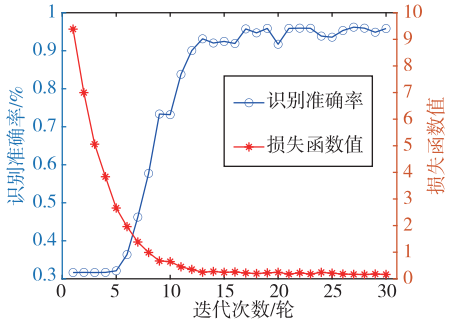
3.3.1 模型验证集性能评估

在相同参数条件下，通过比较分析获得了三种

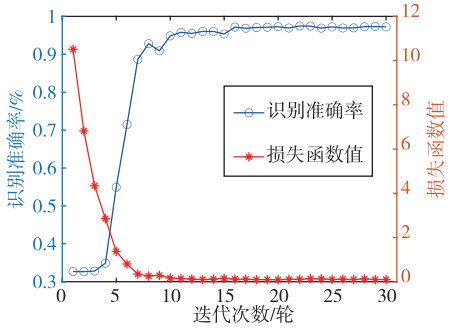
不同网络模型对相同样本的验证集识别准确率和损失函数曲线，训练结果如图 8 所示。CNN 模型和 Mini-Xception 模型在验证集上的识别准确率均小于 MHA-1DMini-Xception 模型的识别准确率，同时 MHA-1DMini-Xception 模型的损失函数曲线收敛远远快于其他两种模型。因此，MHA-1DMini-Xception 模型在验证集上的表现最好。



（a）CNN 验证集



（b）Mini-Xception 验证集



（c）MHA-1DMini-Xception 验证集

图 8　不同模型验证集性能对比

3.3.2　模型测试集性能评估

通过对验证集的识别准确率和损失函数曲线图分析可知，MHA-1DMini-Xception 网络在覆冰等级分类方面性能较为优异。为进一步验证该模型对覆冰等级的识别性能，使用测试样本集对三种网络模型进行比较分析，如表 2 所示，其中 Net1 为 CNN、Net2 为 Mini-Xception、Net3 为 MHA-1DMini-Xception。由表 2 可知，MHA-1DMini-Xception 的平均识别准确性能优于其他两种模型，识别准确率达到了 97.47%，对于二级覆冰识别准确率达到了 99.06%。因此，MHA-1DMini-Xception 模型在覆冰等级识别方面性能最优。

表 2　三种模型测试集准确率对比

网络模型	无覆冰	一级覆冰	二级覆冰	平均识别准确率/%
Net1	89.69	96.17	98.12	94.66
Net2	93.36	98.75	98.20	96.77
Net3	96.56	96.79	99.06	97.47

4　结论

本文提出一种改进的 MHA-1DMini-Xception 模型，在保留 Mini-Xception 模型高效性和较低计算复杂性的同时，对其进行了改进，令原本适用于二维图像信号的模型能有效提取一维时序信号的特征。为提升深度学习模型在 OPGW 覆冰分类方面的准确率，引入了多头注意力机制来捕捉更加丰富的特征信息，并通过多个注意力头并行处理进一步提高了计算效率。经现场数据集验证，MHA-1DMini-Xception 模型对覆冰等级分类识别的准确率达到了 97.47%，证明了 MHA-1DMini-Xception 模型在 OPGW 监测领域具有明显优势。

参考文献：

[1] 黄麟景，周　霄，樊昕昱，等. 多机理融合分布式光纤传感技术研究[J]. 光学学报，2024，44(1)：161-172.
Huang Linjing，Zhou Xiao，Fan Xinyu，et al. Multi-mechanism distributed fiber-optic sensing technology[J]. Acta Optica Sinica，2024，44(1)：161-172.

[2] 张旭苹，张益昕，王　亮，等. 分布式光纤传感技术研究和应用的现状及未来[J]. 光学学报，2024，44(1)：0106001.
Zhang Xuping，Zhang Yixin，Wang Liang，et al. Present situation and future of research and application of distributed optical fiber sensing technology[J]. Acta Optica Sinica，2024，44(1)：0106001.

[3] Ding Z W，Zhang X P，Zou N M，et al. Phi-OTDR based on-line monitoring of overhead power transmission line[J]. Journal of Lightwave Technology，2021，39(15)：5163-5169.

[4] 尚秋峰，樊小凯. 基于 CVMD 和 DBO-SVM 的光纤周界安防信号识别方法[J]. 半导体光电，2024，45(1)：159-166.
Shang Qiufeng，Fan Xiaokai. Fiber optic perimeter security signal recognition method based on CVMD and DBO-SVM [J]. Semiconductor Optoelectronics，2024，45(1)：159-166.

[5] 张智娟，郭文翰，徐志钮，等. 基于 Φ-OTDR 的光纤传感技术原理及其应用现状[J]. 半导体光电，2019，40(1)：9-16.
Zhang Zhijuan，Guo Wenhan，Xu Zhiniu，et al. Principle of

optical fiber sensing technology based on Φ-OTDR and its application status[J]. Semiconductor Optoelectronics, 2019, 40(1): 9-16.

[6] 胡祖翰, 钱 恒, 石先明, 等. 相干衰落抑制Φ-OTDR的分布式光纤周界安防技术[J]. 西南交通大学学报, 2024, 59(3): 564-571.
Hu Zuhan, Qian Heng, Shi Xianming, et al. Distributed optical fiber perimeter security technology based on Φ-OTDR with interference fading suppression[J]. Journal of Southwest Jiaotong University, 2024, 59(3): 564-571.

[7] Coscetta A, Catalano E, Cerri E, et al. Distributed static and dynamic strain measurements in polymer optical fibers[C]// Sensors and Microsystems, 2023: 201-206.

[8] 马国明, 王思涵, 秦炜淇, 等. 输电线路运行状态光纤感知研究与展望[J]. 高电压技术, 2022, 48(8): 3032-3047.
Ma Guoming, Wang Sihan, Qin Weiqi, et al. Research and prospect in optical fiber sensing of transmission line operating conditions[J]. High Voltage Engineering, 2022, 48(8): 3032-3047.

[9] 曲洪权, 吉 祥, 盛智勇, 等. 基于AdaBoost集成学习的光纤振动信号识别分类方法[J]. 激光与光电子学进展, 2022, 59(13): 229-236.
Qu Hongquan, Ji Xiang, Sheng Zhiyong, et al. Recognition and classification method for fiber optical vibration signal using AdaBoost ensemble learning [J]. Laser & Optoelectronics Progress, 2022, 59(13): 229-236.

[10] 王 鸣, 沙 洲, 封 皓, 等. 基于LSTM-CNN的φ-OTDR模式识别[J]. 光学学报, 2023, 43(5): 19-30.
Wang Ming, Sha Zhou, Feng Hao, et al. φ-OTDR pattern recognition based on LSTM-CNN[J]. Acta Optica Sinica, 2023, 43(5): 19-30.

[11] Wu H, Chen J, Liu X, et al. One-dimensional CNN-based intelligent recognition of vibrations in pipeline monitoring with DAS[J]. Journal of Lightwave Technology, 2019, 37(17): 4359-4366.

[12] Zhang S, He T, Fan C, et al. An intrusion recognition method based on the combination of One-dimensional CNN and DenseNet with DAS system[C]//2021 Asia Communications and Photonics Conference, 2021: 1-3.

[13] 白 倩, 罗小波, 母仕林. 基于TA-UNet3+的高分辨率遥感图像地表水体提取[J]. 计算机工程与应用, 2025, 61(13): 245-255.
Bai Qian, Luo Xiaobo, Mu Shilin. Surface water extraction from high-resolution remote sensing images based on TA-UNet3+[J]. Computer Engineering and Applications, 2025, 61(13): 245-255.

[14] 梁秀霞, 夏曼曼, 何月阳, 等. 基于时空多头图注意力网络的交通流预测[J]. 电子学报, 2024, 52(2): 500-509.
Liang Xiuxia, Xia Manman, He Yueyang, et al. Traffic flow prediction based on spatio-temporal multi-head graph attention network[J]. Acta Electronica Sinica, 2024, 52(2): 500-509.

[15] 胡梦楠, 王 蓉, 张文靖, 等. 基于双通道注意力机制的多尺度指代目标分割方法[J/OL]. 计算机辅助设计与图形学学报, 2024: 1-10. (2024-06-03).
Hu Mengnan, Wang Rong, Zhang Wenjing, et al. Multi-scale referring image segmentation based on dual attention[J/OL]. Journal of Computer-Aided Design & Computer Graphics, 2024: 1-10. (2024-06-03).

作者简介：

杨润平(1978—),男,研究生,高级工程师,主要从事电力通信研究工作。