

# 基于多源信息融合与一维卷积神经网络的 低压供电电缆故障诊断研究

李陈莹<sup>1</sup>, 曹京荣<sup>1</sup>, 谭笑<sup>1</sup>, 周立<sup>1</sup>, 张伟<sup>1</sup>, 王齐<sup>2</sup>, 张毅明<sup>2</sup>, 吴淑群<sup>2\*</sup>

(1. 国网江苏省电力有限公司 电力科学研究院, 江苏 南京 211103;

2. 东南大学 溧阳研究院, 江苏 常州 213300)

## Research on Low Voltage Power Supply Cable Fault Diagnosis Based on Multi-Source Information Fusion and One Dimensional Convolutional Neural Network

LI Chenying<sup>1</sup>, CAO Jingying<sup>1</sup>, TAN Xiao<sup>1</sup>, ZHOU Li<sup>1</sup>, ZHANG Wei<sup>1</sup>,  
WANG Qi<sup>2</sup>, ZHANG Yiming<sup>2</sup>, WU Shuqun<sup>2\*</sup>

(1. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, China;

2. Liyang Research Institute, Southeast University, Changzhou 213300, China)

**Abstract:** [Objective] To address issues in traditional low-voltage power cable fault diagnosis, such as reliance on a single signal, insufficient feature extraction, and weak anti-interference capability, an intelligent diagnostic strategy is proposed that can achieve high robustness and high-precision identification under complex operating conditions.

[Methods] An intelligent diagnostic method integrating variational mode decomposition-Hilbert transform (VMD-HT) and multi-source one-dimensional convolutional neural network (MS-1DCNN) was proposed. A time-frequency analysis framework was constructed using VMD and HT to adaptively decompose signals of different modes and quantify feature parameters. Meanwhile, the MS-1DCNN structure was designed to achieve unified modeling and diagnosis of multiple types of cable faults. [Results] The experimental results demonstrated that the proposed MS-1DCNN diagnostic model outperformed conventional methods in terms of fault feature separability, classification accuracy, and stability under complex noise conditions. Superior robustness to hyperparameter variations was also verified. [Conclusion] The proposed MS-1DCNN model significantly enhances the reliability of fault identification in low-voltage cables, making it suitable for online monitoring and early warning scenarios in actual power grids. It provides a scalable technical solution

for ensuring the operational safety of low-voltage distribution systems.

**Key words:** low-voltage power cable; fault diagnosis; variational mode decomposition; Hilbert transform; multi-source one-dimensional convolutional neural network

**摘要:** [目的]为解决传统低压供电电缆故障诊断中存在的信号依赖单一、特征提取不足及抗干扰能力弱的问题,提出一种能够在复杂工况下实现高鲁棒性与高精度识别的智能诊断策略。[方法]本文提出一种融合变分模态分解-希尔伯特变换(VMD-HT)和多源一维卷积神经网络(MS-1DCNN)的智能诊断方法。利用VMD与HT构建时频分析框架,对不同模态信号进行自适应分解与特征参数量化;同时设计MS-1DCNN结构,实现对多类型电缆故障的统一建模与诊断。[结果]试验结果表明,所提诊断模型MS-1DCNN在故障特征分离度、分类精度以及复杂噪声环境下的稳定性方面均优于传统方法,且对超参数变化鲁棒性强。[结论]本文所提MS-1DCNN模型能够显著增强低压电缆故障的识别可靠性,适用于实际电网的在线监测和早期预警场景,为低压配电系统的运行安全提供了可推广的技术路径。

**关键词:** 低压供电电缆;故障诊断;变分模态分解;希尔伯特变换;多源一维卷积神经网络

基金项目: 国网江苏省电力有限公司科技项目(J2025032)

State Grid Jiangsu Electric Power Co., Ltd. Science and Technology Project (J2025032)

## 0 引言

随着智能电网与能源互联网建设的不断推

进, 低压供电电缆作为电力传输的关键载体, 其运行可靠性对配电网的安全性与经济性具有决定性影响。然而, 由于电缆长期埋设于复杂地质环境, 易受绝缘老化、外力破坏及过电压冲击等多重因素影响, 导致单相接地、相间短路等故障频发。传统故障诊断方法(如阻抗法、行波法)主要依赖单一信号源进行阈值判断, 易受噪声干扰且对早期隐性故障敏感度不足。随着智能电网系统中智能装置和传感器的广泛应用, 变电站低压线路结构日益复杂, 故障信号数据的非线性特征显著增强, 导致电缆故障辨识难度加大。

近年来, 深度学习技术为低压供电电缆故障诊断提供了新思路。针对电缆故障信号的非平稳特性与多模态耦合特点, 本文提出一种多源一维卷积神经网络(Multi-Source One-Dimensional Convolutional Neural Network, MS-1DCNN)深度融合的智能诊断模型。该模型通过双通道并行架构同步处理电流与电压信号, 利用一维卷积核在时域维度深度挖掘故障特征, 并引入通道注意力机制实现特征自适应加权, 从而有效提升了故障诊断的准确性和鲁棒性。

针对低压供电电缆故障诊断难题, 本文提出一种变分模态分解-希尔伯特变换(Variational Mode Decomposition-Hilbert Transform, VMD-HT)和 MS-1DCNN 融合的智能诊断方法, 旨在突破传统方法的局限性, 实现多源异构信号的有效融合与深层特征挖掘。通过注入信号试验平台验证, 该方法在低信噪比环境下性能优越, 为低压电缆故障诊断提供了可靠解决方案。

## 1 电缆检测及诊断方法

### 1.1 注入信号故障检测法

注入信号法作为一种主动式激励-响应诊断技术<sup>[1-2]</sup>, 通过零序信号的电气隔离特性, 有效规避三相不平衡电流干扰, 实现对低压电缆的实时在线监测与故障精确定位。通过建立电缆分布参数等效电路模型, 解析注入信号在故障状态下的幅值-相位响应特性, 求解出关键电参数, 实现对故障状况的精确诊断。注入信号法原理如图 1 所示。

图 1 中,  $E_A$ 、 $E_B$ 、 $E_C$  为低压配电网系统的三相电源;  $U_{sig}$  为注入信号源;  $T$  为注入变压器;  $C_A$ 、

$C_B$ 、 $C_C$  与  $R_A$ 、 $R_B$ 、 $R_C$  分别为电缆三相对地电容和对地绝缘电阻;  $R_G$  为模拟故障电阻。电缆电路正常工作时, 零序注入信号由于对称性不会在电源与负载间流通, 不会影响到其他正常负载设备的运作<sup>[3]</sup>; 当发生单相接地故障时, 该信号将沿电缆故障相流动并经接地点入地, 形成电流环路。通过分析电流信号的幅值与相位变化, 可综合诊断故障<sup>[4]</sup>。




图 1 注入信号原理示意图

Fig. 1 Schematic diagram of injection signal principle

### 1.2 VMD

VMD<sup>[5-6]</sup>将复杂信号分解为多个具有稀疏性和有限带宽特性的本征模态函数(Intrinsic Mode Function, IMF), 同时确定每个 IMF 的中心频率。相较于传统经验模态分解, VMD 有效抑制了模态混叠现象, 并具有更强的抗噪能力与稳定性<sup>[7]</sup>。

VMD 的核心思想是在约束条件下最小化所有模态函数的带宽之和。假设输入信号  $f(t)$  通过式(1)被分解为  $k$  个 IMF 分量, 每个 IMF 对应一个中心频率  $\omega_k$ 。

VMD 算法流程为: ①初始化  $\hat{u}_k^1$ 、 $\hat{\omega}_k^1$ 、 $\hat{\lambda}_k^1$ , 令  $n=0$ ; ②令  $n=n+1$ , 根据式(2)~(4)分别更新  $u_k^1$ 、 $\omega_k^1$  和  $\lambda_k^1$ , 得到  $\hat{u}_k^{n+1}(\omega)$ 、 $\hat{\omega}_k^{n+1}$  和  $\hat{\lambda}_k^{n+1}(\omega)$ ; ③重复步骤 ①、②, 直至满足式(4)的收敛条件后停止更新, 并输出  $k$  个 IMF 分量。

$$\hat{u}_k^{n+1}(\omega) =$$

$$\frac{\hat{f}(\omega) \sum_{i < k} \hat{u}_i^{n+1}(\omega) - \sum_{i > k} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (1)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (2)$$

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau [\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)] \quad (3)$$

$$\sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (4)$$

式中: $\alpha$ 为惩罚系数; $\tau$ 为保真系数; $\varepsilon$ 为收敛精度,用于判断算法是否收敛; $u_k$ 为模态函数; $\omega_k$ 为中心频率; $\lambda$ 为拉格朗日乘数; $\wedge$ 为傅里叶变换操作。

本文针对包含不同频率分量的故障电流信号,提出一种基于模态分量之间互信息(Mutual Information, MI)关系的模态个数选取方法。MI主要描述了两个变量的依赖关系,其大小反应了变量之间的关联程度,当变量相互独立时其值为零。对于一组变量( $x, y$ )的标准互信息(Normalized MI, NMI),其计算式为

$$NMI(X, Y) = \sqrt{\frac{MI(X, Y)}{H(X) + H(Y)}} \quad (5)$$

式中: $H(X)$ 、 $H(Y)$ 分别为变量 $x, y$ 的信息熵。

因此,基于MI概念,提出一种新的评估函数,通过计算模态本身MI之和以及原始信号与各模态MI之和的比值,以此评估信号的特征信息量和模态分解的有效性,计算式可表示为

$$NMI_{\text{function}} = \frac{\sum_{k=1}^{K-1} NMI[\text{mod}(k), \text{mod}(k+1)]}{\sum_{k=1}^K NMI[\text{mod}(k), f]} \quad (6)$$

式中: $f$ 为VMD的输入信号; $\text{mod}(k)$ 为经过VMD分解得到的第 $k$ 个IMF分量。

根据对欠分解与过分解情况的分析,在进行VMD模态分解时,不同模态分量之间的MI之和 $\sum_{k=1}^{K-1} NMI[\text{mod}(k), \text{mod}(k+1)]$ 应保持最小,保证不同模态的频率成分有效分离,以避免出现过分解现象。因此,当MI函数取 $NMI_{\text{function}}$ 最小时,对应的分解层数 $k$ 可认为是最佳层数。

### 1.3 HT

HT<sup>[8-9]</sup>是信号处理的核心工具,本质是对输入信号 $x(t)$ 进行线性时不变卷积运算,其脉冲响应为 $h(t) = 1/(\pi t)$ ,数学表达式为

$$x^h(t) = x(t) * h(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (7)$$

在频域层面,HT等效于对信号频谱进行 $-90^\circ$ 相移处理,由此消除频谱冗余信息<sup>[10]</sup>。通过解析信号可以求得原信号的瞬时幅值 $A(n)$ 、瞬时相位 $\varphi(n)$ 和瞬时频率 $f(n)$ ,其计算式分别为

$$A(n) = \sqrt{x(n)^2 + x^h(n)^2} \quad (8)$$

$$\varphi(n) = \arctan \left[ \frac{x^h(n)}{x(n)} \right] \quad (9)$$

$$f(n) = \frac{f_s}{2\pi} [\varphi(n-1) - \varphi(n)] \quad (10)$$

该方法突破了传统傅里叶变换使用全局固定基函数的局限,实现了信号的时频局部化分析。

## 1.4 MS-1DCNN 智能诊断方法

### 1.4.1 卷积神经网络

卷积神经网络(Convolutional Neural Network, CNN)专为网格化数据设计,在图像处理、语音识别等领域表现出色。其网络结构由卷积层、池化层、全连接层及Softmax分类层等核心模块构成<sup>[11-12]</sup>。

其中,卷积层使用滑动窗口提取局部特征,显著降低网络复杂度;池化层压缩特征图,增强模型鲁棒性;全连接层整合卷积层及池化层的局部特征,完成最终决策。而Softmax分类层则将特征映射转换为概率分布,实现多类别决策输出<sup>[13-14]</sup>。

### 1.4.2 基于MS-1DCNN的故障识别方法

基于CNN理论框架,本文构建一种MS-1DCNN模型,用于低压供电电缆的故障识别。该模型采用端到端架构实现多源特征提取与决策融合,其模型整体结构如图2所示,主要包含三级模块:(1)多源数据预处理模块;(2)多通道特征提取模块;(3)通道注意力机制的特征融合模块。

图2中,数据预处理后,系统将电流与电压信号的相关故障特征信息输入到通道注意力模块中,动态分配各分支的权重,并输出耦合特征,使得网络聚焦关键局部区域。最后,Softmax分类层将连接层的特征向量转换为概率分布,确定故障类型。

#### (1) 多源数据预处理

首先采用奇异值分解-小波变换混合去噪算法对采集的故障数据进行预处理,在保留故障瞬态特征的同时有效滤除白噪声。同时,通过随机重叠采样技术构建四维输入向量,提升数据集的多样性,增强模型对电缆故障类型识别的泛化能力。

通过在原始数据样本的时间轴上随机生成起始点,设置新生成数据样本的长度 $l$ 为400个数据点,覆盖2个工频周期的稳态数据。将故障电

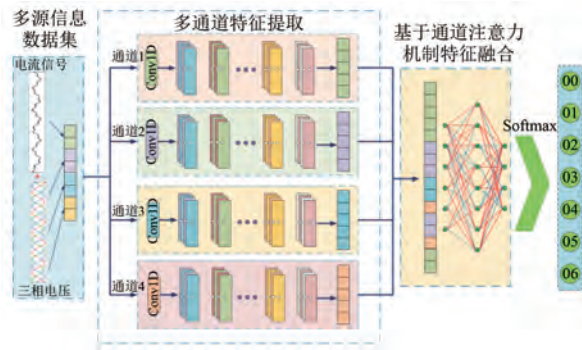


图 2 MS-1DCNN 的整体模型结构

Fig. 2 The overall model structure of MS-1DCNN

流和 A 相、B 相、C 相电压的时序数据(4×400)随机重叠采样,连接形成输入层数据(1×1 600)。

(2) 基于 1D-CNN 的多通道特征提取

传统 CNN 仅能在单一尺度上提取特征,可能导致复杂工况下丢失关键信息,影响模型的识别效果。而多通道 CNN 通过在不同通道分支上并行提取故障信号的融合特征,对比电压电流的时序变化特性,能够更全面地捕获故障相关信息,显著提升特征提取的完整性和精度。

本文设计了 1DCNN 的特征提取模块,结构如图 3 所示<sup>[15]</sup>。图 3 中,将得到的故障特征信息输入到通道 1 中,经过一维卷积模块对特征进行提取。以图 3 所示的通道 1 为例,特征提取部分包含 4 个卷积层。第一个卷积层采用 51×1 的宽卷积核,捕获丰富的信号特征并增强模型鲁棒性,其余卷积层的核大小为 3×1,更关注信号细节变化。每个卷积层后均加入概率参数  $p = 0.1$  的 Dropout 层和步长为 2 的最大池化层,Dropout 层随机舍弃 10% 的神经元以防止过拟合,池化层则对特征进行降维,提取关键信息。MS-1DCNN 模型内单通

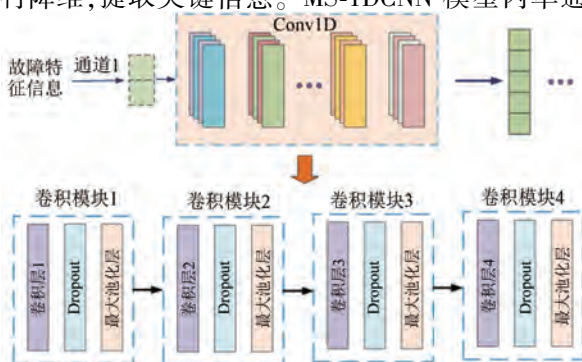


图 3 1DCNN 特征提取模块

Fig. 3 1DCNN feature extraction module

道具体参数配置如表 1 所示。

表 1 特征提取模块结构参数

Tab. 1 Feature extraction module structure parameters

模块类别	卷积核大小	步长	输入	输出
卷积层 1	51	1	1	1 024
卷积层 2	3	1	1 024	512
卷积层 3	3	1	512	128
卷积层 4	3	1	128	32
最大池化层	—	2	—	—

将预处理过程得到的输入层数据(1×1 600)均分为四个样本(4×400),分别表示故障电流和 A、B、C 三相电压信息。

(3) 基于通道注意力机制的特征融合

通道注意力机制动态调整 CNN 中特征图各通道的权重<sup>[16]</sup>,强化与预测目标强相关的关键特征通道,抑制冗余或噪声信息通道,显著提升模型的特征表达能力。针对电缆故障特征复杂、干扰因素多的特点,引入通道注意力机制,可以提升模型的诊断性能<sup>[17-18]</sup>。

采用 SENet 模块通过压缩、激励和重缩放三阶段,实现对通道权重的自适应学习,其架构如图 4 所示。该机制能动态评估各通道的相对重要性,强化关键特征,抑制冗余信息<sup>[19]</sup>。

图 4 中,  $F_{sq}$  为通道的全局平均池化(压缩过程),将  $W \times C$  的特征图压缩为  $1 \times C$  的一维向量,  $C$  为通道数,  $W$  为特征宽度。该向量由各通道的全局平均池化标量  $X_{sq}$  组成,表征了通道的全局信息响应<sup>[20]</sup>,其计算过程如式(11)所示:

$$X_{sq-c} = F_{sq}(X_c) = \frac{1}{W} \sum_{i=1}^W X_c(i) \quad (11)$$

式中:  $X_c$  为  $C$  通道的数据;  $X_{sq-c}$  为经过通道注意力机制转换后的特征标量值。




图 4 通道注意力机制示意图

Fig. 4 Schematic diagram of channel attention mechanism

图4中,  $F_{ex}$  为激励阶段, 通过将压缩得到的  $1 \times C$  一维向量融入全连接层, 评估各个通道的重要程度。激励操作可以将标量向量  $V_1$  转化为一维权重向量  $V_2$ , 从而表征每个通道的重要性。

最终, 在图4的  $F_{scale}$  阶段, 通过重缩放操作, 将计算得到的权重向量与输入特征逐元素相乘, 将标准化后的权重应用于各个通道, 从而实现对不同通道特征的动态增强和抑制<sup>[21]</sup>, 其具体表达式为

$$V_2 = \sigma[w_1 f(w_0 V_1) + b_0 + b_1] \quad (12)$$

$$X' = X \cdot V_2 \quad (13)$$

式中:  $\sigma(\cdot)$  为 sigmoid 函数;  $f(\cdot)$  为 ReLU 函数;  $w_0, w_1$  为全连接层参数;  $b_0, b_1$  为偏置项;  $X'$  为经过通道注意力机制后的最终输出特征;  $V_1$  为标量向量;  $V_2$  为一维权重向量。

智能故障诊断方法如下: 首先, 采集涵盖单相接地、相间短路等典型故障的电缆运行数据, 对数据进行预处理并构建多工况故障样本数据库。随后, 初始化网络参数并输入故障数据进行模型训练。通过调整超参数优化模型性能, 同时利用验证集评估误差, 迭代至最优。最后, 测试集输入最佳模型, 预测故障类别, 实现了从信号到决策的智能映射, 为电缆监测提供高效方案。

## 2 试验平台

真实电网中的故障具有随机性和不可预测性。为模拟真实电网故障, 在实验室搭建了 380 V 低压电缆试验平台, 避免破坏性试验<sup>[22]</sup>。实际测试时, 先打开隔离变压器确保带电运行正常后, 再向系统注入特征信号并开展故障模拟试验。试验的具体配置如图5所示。




图5 模拟试验平台配置图

Fig. 5 Simulation experiment platform configuration diagram

注入信号参数设置: 选择 180 Hz、15 V 的正弦注入信号。既能避免被工频谐波掩盖, 同时又符合 10 kV 及以下系统电压偏移率  $\leq 7\%$  的要求。

电容设置: 通常低压供电电缆线路中的固有泄漏电流小于 50 mA, 模拟真实的电缆环境, 配置不平衡的三相接地电容, 使电缆线路产生不同幅度的泄漏电流。此时, 泄漏电流有效值分别为 0、10.3 mA、20.7 mA、31.1 mA 和 41.4 mA。

电阻设置: 模拟不同绝缘损坏程度, 试验中设置发生故障相线的对地电阻分别为 500  $\Omega$ 、1 000  $\Omega$ 、2 000  $\Omega$ 、3 000  $\Omega$ 、4 000  $\Omega$  和 5 000  $\Omega$ 。其中, 500  $\Omega$  对应局部绝缘破损, 5 000  $\Omega$  模拟高阻接地故障。

## 3 结果分析

### 3.1 数据样本分析

为系统评估所提方法的诊断性能, 基于模拟平台构建了包含 AG、BG、CG、ABG、ACG、BCG 和 ABCG 七类故障模式的测试集, 涵盖不同电容、故障电阻和泄漏电流条件, 共 1 200 组样本, 包括 150 组正常状态数据。

以泄漏电流 0、故障电阻 1 000  $\Omega$  的故障信号为例, 不同故障类型下的电流波形如图6所示。由图6(a)和图6(b)可知, 在相同泄漏电流与故障电阻条件下, 单相故障与两相故障的电流波形特征难以区分, 因此对故障类型进行区分识别是本文的研究重点。

### 3.2 VMD-HT 的故障判据

针对多相故障中并联电阻导致的特征弱化问题, 本文使用 VMD-HT 联合分析方法。为确保检测判据适用于不同故障工况, 基于第2章试验获取的单相故障数据进行分析。通过分析故障发生前后特征信号电流幅值与相位变化特征, 结果如图7所示。

由图7(a)和(c)可知, 故障后的电流幅值随故障电阻的增加而减小。故障电阻 5 000  $\Omega$  时理论电流幅值变化量仅为 0.41 mA, 而试验测试变化量为 0.19 mA, 这是故障电阻电流与对地电容电流矢量合成的结果。相比之下, 由图7(b)和(c)可知, 相位变化更显著(理论最小 11.12°, 实测 11.94°), 且对故障电阻的鲁棒性更强。因此, 本文选择相位变化特征作为故障检测的判据。




图 6 不同故障类型下的电流信号  
 Fig. 6 Current signals under different fault types

### 3.3 MS-1DCNN 对故障识别结果

为验证模型的有效性,对比分析了不同超参数与其他深度学习算法的故障识别性能。在第 2 节参数条件下采集 10 500 个故障数据(每类 1 500 个),并按照 7:2:1 的比例划分为训练集、验证集与测试集,用于模型训练研究。

结果除准确率外,还引用了精确率  $P$ 、召回率  $R$  和调和平均值  $F_1$  作为评估指标,对比分析不同超参数与模型之间的故障类型识别性能<sup>[23-24]</sup>,其计算式为

$$\begin{cases} P = \frac{TP}{TP + FP} \\ R = \frac{TP}{TP + FN} \\ F_1 = \frac{2PR}{P + R} \end{cases} \quad (14)$$

式中:TP 为检测正确的目标数量;FP 为错误的目




图 7 基于故障电流幅值与相位变化特征检测结果  
 Fig. 7 Detection results based on fault current amplitude and phase change characteristics

标数量;FN 为漏检的目标数量。

#### 3.3.1 模型识别有效性验证

在低压供电电缆故障识别领域,模型的稳定性与泛化能力是评价算法有效性的核心指标。MS-1DCNN 模型的训练结果如图 8 所示。由图 8 可知,随着迭代次数增加,MS-1DCNN 模型的损失值逐渐减小、预测性能随之提升。模型的识别准确率随迭代次数增加快速上升,并在迭代 15 次后逐渐趋于稳定,最终超过 99%,证明其对低压电缆故障的高精度识别能力。

为进一步量化模型的性能,采用混淆矩阵展示模型对不同故障的分类效果,如图 9 所示。由图 9 可知,MS-1DCNN 模型对不同故障类型的平均识别准确率为 99.6%,充分证明了 MS-1DCNN 具有

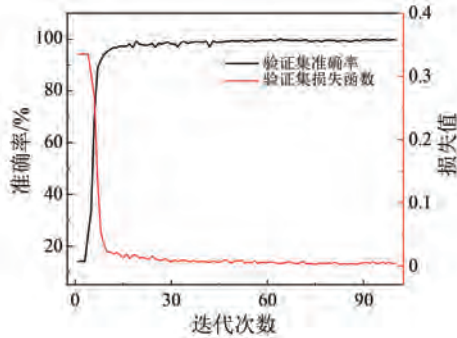


图 8 模型的训练准确率及损失函数曲线

Fig. 8 Training accuracy and loss function curves of the model

真实类别	AG	150 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	BG	0 0.0%	150 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	CG	0 0.0%	0 0.0%	150 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	ABG	4 0.4%	0 0.0%	0 0.0%	146 13.9%	0 0.0%	0 0.0%	0 0.0%	97.3% 2.7%
	ACG	0 0.0%	0 0.0%	0 0.0%	0 0.0%	150 14.3%	0 0.0%	0 0.0%	100% 0.0%
	BCG	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	150 14.3%	0 0.0%	100% 0.0%
	ABCG	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	150 14.3%	100% 0.0%
		97.4% 2.6%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	99.6% 0.4%
	AG	BG	CG	ABG	ACG	BCG	ABCG	预测类别	

图 9 模型识别结果的混淆矩阵

Fig. 9 Confusion matrix of model recognition results

较好的识别效果。

### 3.3.2 不同超参数的对比分析

超参数对模型性能至关重要<sup>[25-26]</sup>。为研究不同卷积层数对模型的影响效果,选取卷积层为3、4、5、6时对比分析模型的训练效果,其他参数保持不变,结果如图10所示。

由图10可知,卷积层数为4时,MS-1DCNN模型识别故障的准确率、精确率、召回率和 $F_1$ 均达到最优性能。但当层数进一步增加时,其识别的准确率反而会降低,这是因为过多的卷积层数会导致模型始终关注局部细节,而无法有效反映数据与类别之间的映射关系,导致模型识别性能下降。因此,本文的卷积层数设置为4层。

此外,卷积核大小影响模型对全局和局部特征的关注。试验对比分析了4种卷积核参数组合,不同参数组合对模型的训练结果如图11所示。

由图11可知,采用全等卷积核(3,3,3,3)识别精度普遍更低,而差异化组合(51,3,3,3)可以




图 10 不同卷积层数对模型训练结果的影响

Fig. 10 Impact of different convolutional layer numbers on model training results

更好的关注信号的细节变化,识别精度高,故本文选择该结构。




图 11 不同卷积核设置对模型训练结果的影响

Fig. 11 Impact of different convolutional kernel settings on model training results

综上所述,MS-1DCNN模型在卷积层数为4、卷积核结构为(51,3,3,3)时,准确率、精确率、召回率和 $F_1$ 分数评价指标分别达到99.62%、99.57%、99.57%和99.71%,验证了MS-1DCNN模型超参数设置的合理性。

### 3.3.3 不同识别模型的对比分析

为了验证本文所提MS-1DCNN模型的优越性,将其与1DCNN、长短期记忆(Long Short-Term Memory, LSTM)网络和深度神经网络(Deep Neural Network, DNN)3种传统深度学习模型进行对比测试<sup>[27-28]</sup>。各模型训练完成后的识别曲线分布如图12所示。

由图12可知,MS-1DCNN、1DCNN、LSTM和DNN最终的平均识别准确率分别为99.6%、96.7%、93.2%、84.9%。本文所提MS-1DCNN模型通过引入通道注意力机制,在不同通道分支上

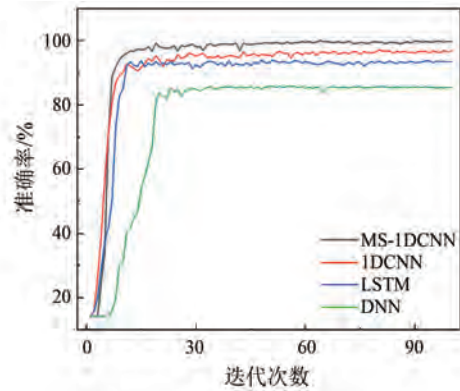


图 12 各模型的准确率曲线  
 Fig. 12 Accuracy curves of different models

真实类别	AG	BG	CG	ABG	ACG	BCG	ABCG	准确率
AG	150 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
BG	0 0.0%	150 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
CG	0 0.0%	0 0.0%	150 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
ABG	4 0.4%	0 0.0%	0 0.0%	146 13.9%	0 0.0%	0 0.0%	0 0.0%	97.3%
ACG	0 0.0%	0 0.0%	0 0.0%	0 0.0%	150 14.3%	0 0.0%	0 0.0%	100%
BCG	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	150 14.3%	0 0.0%	100%
ABCG	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	150 14.3%	100%
	97.4%	100%	100%	100%	100%	100%	100%	99.6%
	2.6%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.4%
	AG	BG	CG	ABG	ACG	BCG	ABCG	

(a)MS-1DCNN

真实类别	AG	BG	CG	ABG	ACG	BCG	ABCG	准确率
AG	145 13.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	4 0.4%	96.7%
BG	0 0.0%	147 14.0%	0 0.0%	1 0.1%	0 0.0%	2 0.2%	0 0.0%	98.0%
CG	0 0.0%	0 0.0%	149 14.2%	0 0.0%	0 0.0%	1 0.1%	0 0.0%	99.3%
ABG	0 0.0%	5 0.5%	0 0.0%	145 13.8%	0 0.0%	0 0.0%	0 0.0%	96.7%
ACG	6 0.6%	0 0.0%	4 0.4%	0 0.0%	140 13.3%	0 0.0%	0 0.0%	93.3%
BCG	0 0.0%	3 0.3%	0 0.0%	0 0.0%	0 0.0%	143 13.6%	4 0.4%	95.3%
ABCG	3 0.3%	0 0.0%	0 0.0%	1 0.1%	0 0.0%	0 0.0%	146 13.9%	97.3%
	94.2%	94.8%	97.4%	98.6%	99.3%	97.9%	94.8%	96.7%
	5.8%	5.2%	2.6%	1.4%	0.7%	2.1%	5.2%	3.3%
	AG	BG	CG	ABG	ACG	BCG	ABCG	

(b)1DCNN

真实类别	AG	BG	CG	ABG	ACG	BCG	ABCG	准确率
AG	148 14.1%	0 0.0%	0 0.0%	2 0.2%	0 0.0%	0 0.0%	0 0.0%	98.7%
BG	0 0.0%	145 13.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	96.7%
CG	0 0.0%	0 0.0%	148 14.1%	0 0.0%	1 0.1%	0 0.0%	1 0.1%	98.7%
ABG	0 0.0%	3 0.3%	0 0.0%	147 14.0%	0 0.0%	0 0.0%	0 0.0%	98.0%
ACG	12 1.1%	0 0.0%	1 0.1%	0 0.0%	150 14.3%	0 0.0%	0 0.0%	91.3%
BCG	0 0.0%	9 0.9%	0 0.0%	0 0.0%	0 0.0%	135 12.9%	6 0.6%	90.0%
ABCG	8 0.8%	0 0.0%	0 0.0%	10 1.0%	0 0.0%	5 0.5%	119 11.3%	79.3%
	88.1%	87.9%	99.3%	89.6%	99.3%	96.4%	94.4%	93.2%
	11.9%	12.1%	0.7%	10.4%	0.7%	3.6%	5.6%	6.8%
	AG	BG	CG	ABG	ACG	BCG	ABCG	

(c)LSTM

真实类别	AG	BG	CG	ABG	ACG	BCG	ABCG	准确率
AG	142 13.5%	0 0.0%	1 0.1%	0 0.0%	7 0.7%	0 0.0%	0 0.0%	94.7%
BG	0 0.0%	150 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
CG	0 0.0%	0 0.0%	150 14.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100%
ABG	0 0.0%	0 0.0%	0 0.0%	150 14.3%	0 0.0%	0 0.0%	0 0.0%	100%
ACG	0 0.0%	0 0.0%	0 0.0%	0 0.0%	150 14.3%	0 0.0%	0 0.0%	100%
BCG	136 13.0%	6 0.6%	2 0.2%	0 0.0%	0 0.0%	0 0.0%	6 0.6%	90.0%
ABCG	0 0.0%	0 0.0%	0 0.0%	1 0.1%	0 0.0%	0 0.0%	149 14.2%	99.3%
	51.1%	96.2%	98.0%	99.3%	95.5%	NaN%	96.1%	84.6%
	48.9%	3.8%	2.0%	0.7%	4.5%	NaN%	3.9%	15.1%
	AG	BG	CG	ABG	ACG	BCG	ABCG	

(d)DNN

图 13 各模型混淆矩阵对比

Fig. 13 Comparison of confusion matrices for different models

同时为了更直观地了解数据在模型中的分布变化情况,采用 T-SNE 方法<sup>[29]</sup>对故障的分类诊断过程可视化,如图 14 所示。其中,分类标签 0~6 分别代表 AG、BG、CG、ABG、ACG、BCG 和 ABCG 七种故障类型。

并行提取故障电流与电压信息的融合特征,相较于传统 1DCNN 模型具有更高的识别准确率。同时,MS-1DCNN 模型在收敛速度和诊断稳定性方面均表现出明显优势。

不同深度学习混淆矩阵对比结果如图 13 所示。由图 13 可知,传统的 1DCNN 和 LSTM 模型,在每个类别的故障预测方面均具有误判现象,在 ABCG 故障的识别召回率仅为 79.3%。而 DNN 模型虽然大多数故障类型识别效果较好,但难以区分 BCG 与 AG 故障,整体识别准确率仅为 84.9%。相比其他模型,本文所提 MS-1DCNN 模型误判率最低,准确率最高,性能最优。

由图 14 可知,MS-1DCNN 能有效分离不同故障特征,形成清晰聚类。传统 1DCNN 和 LSTM 存在混叠,DNN 则完全混淆 BCG 与 AG 故障。MS-1DCNN 通过通道注意力机制自适应分配权重,在故障识别中表现最优。

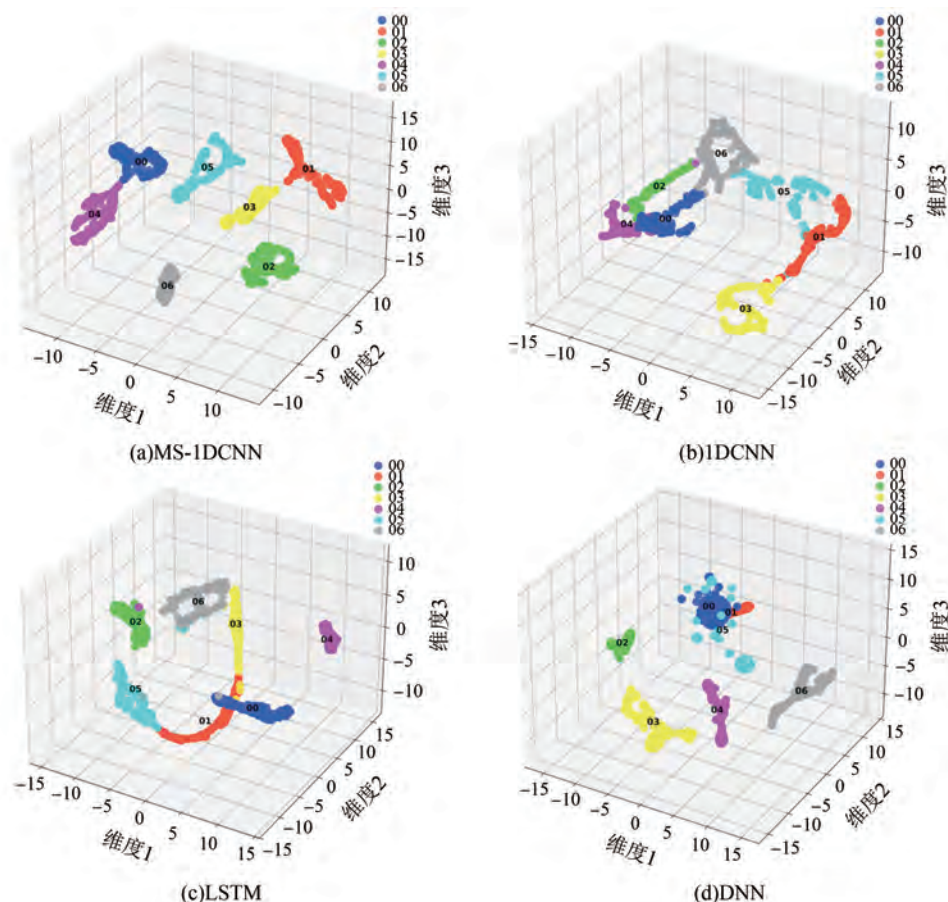


图 14 各模型的 T-SNE 可视化结果

Fig. 14 T-SNE visualization results of different models

## 4 结语

本文针对低压供电电缆故障诊断中传统方法依赖单一信号源、特征提取能力不足等问题,提出一种融合 VMD-HT 与 MS-1DCNN 的智能诊断方法。通过试验验证与对比分析,得出以下结论。

(1) 基于 VMD-HT 的信号预处理技术能够自适应分解多分量故障信号,结合 HT 精准提取时频域特征,有效解决了传统方法中特征冗余与噪声干扰的问题,为后续诊断提供了高区分度的故障特征。

(2) 本文所提的 MS-1DCNN 通过多通道并行特征提取与通道注意力机制,有效实现了多源异构数据的深度特征融合与分类决策。试验表明,在相同噪声环境下,MS-1DCNN 的故障识别准确率高达 99.6%,且对早期隐性故障的敏感度提升显著。

(3) 本文所提诊断方法突破了传统阈值判

断与人工经验依赖的局限,在复杂工况下仍能保持高可靠性,为低压电缆智能化运维提供了数据驱动的解决方案。与传统方法相比,所提 MS-1DCNN 模型故障识别精度高,且对超参数变化鲁棒性更强。

本文所提诊断方法为低压电缆智能化诊断提供了新思路,基于多源信息融合与深度学习协同作用的框架也为电力设备状态监测领域的研究提供了重要参考,对提升电网运行可靠性具有积极的工程实践价值。

### 利益冲突声明

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

### 作者贡献

李陈莹、曹京荣、谭笑和张毅明进行了方案设

计、内容总结与论文撰写,周立、张伟进行了试验研究,王齐、吴淑群参与了论文的审核与修改。所有作者均阅读并同意了最终稿件的提交。

The scheme design, content summarization, and paper writing were conducted by Li Chenying, Cao Jingying, Tan Xiao, and Zhang Yiming. The experimental research was carried out by Zhou Li and Zhang Wei. The paper review and revision were participated in by Wang Qi and Wu Shuqun. All authors have read and approved the final version of the paper for submission.

### 参考文献

- [ 1 ] 张智, 李富, 王国宇, 等. 基于零序电流注入的配电网故障自愈控制方法[J]. 电力科学与技术, 2025, 40(1): 92-100.
- Zhang Z, Li F, Wang G Y, et al. Fault self-healing control method for distribution network based on zero-sequence current injection [J]. Journal of Electric Power Science and Technology, 2025, 40(1): 92-100.
- [ 2 ] 余娜. 基于分布式零序 CT 无源载波信号的配电网单相接地故障选线与定位研究[D]. 武汉: 武汉大学, 2021.
- Yu N. Study on faulted line detection and fault location in distribution networks based on zero sequence CT passive carrier signals [D]. Wuhan: Wuhan University, 2021.
- [ 3 ] Niu L, Wu G Q, Xu Z S. Single-phase fault line selection in distribution network based on signal injection method [J]. IEEE Access, 2021, 9: 21567-21578.
- [ 4 ] 王尉军, 陈旻, 殷慧, 等. XLPE 电缆绝缘状态低频信号感应在线监测技术研究[J]. 现代电力, 2025, 42(2): 393-400.
- Wang W J, Chen M, Yin H, et al. Research on online monitoring technology for XLPE cable insulation characteristics based on low frequency signal induction [J]. Modern Electric Power, 2025, 42(2): 393-400.
- [ 5 ] 陈皇熹, 方春华, 普子恒, 等. 基于 VMD-WVD 相位法的长电缆局放双端定位[J]. 电力工程技术, 2022, 41(3): 171-177.
- Chen H X, Fang C H, Pu Z H, et al. Double-ended positioning of partial discharge for long cable based on VMD-WVD phase method [J]. Electric Power Engineering Technology, 2022, 41(3): 171-177.
- [ 6 ] 汪晋豪, 方春华, 高广德, 等. 基于 VMD-WVD 与 AlexNet 的 10 kV T 形电缆终端局放类型识别[J]. 武汉大学学报(工学版), 2025, 58(9): 1453-1461.
- Wang J H, Fang C H, Gao G D, et al. 10 kV T-shaped cable terminal partial discharge recognition based on VMD-WVD and AlexNet [J]. Engineering Journal of Wuhan University, 2025, 58(9): 1453-1461.
- [ 7 ] 李志福. 基于 VMD 煤矿电力电缆故障定位技术研究[J]. 煤炭科技, 2025, 46(1): 115-118+124.
- Li Z F. Research on fault location technology for coal mine power cable based on VMD [J]. Coal Science & Technology Magazine, 2025, 46(1): 115-118+124.
- [ 8 ] 刘桦, 刘军, 冯艳君, 等. 基于希尔伯特变换的相位误差补偿方法[J]. 组合机床与自动化加工技术, 2025(8): 9-13.
- Liu H, Liu J, Feng Y J, et al. A phase error compensation method based on Hilbert transform [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2025(8): 9-13.
- [ 9 ] 白莹. 基于分数阶 Hilbert 变换的电路故障诊断研究[J]. 流体测量与控制, 2023, 4(4): 59-63+69.
- Bai Y. Research on circuit fault diagnosis based on fractional order Hilbert transformation [J]. Fluid Measurement & Control, 2023, 4(4): 59-63+69.
- [ 10 ] 蔡改贫, 李波波, 赵鑫, 等. 基于自适应 VMD-Hilbert 的球磨机负荷参数预测[J]. 传感器与微系统, 2023, 42(9): 133-136.
- Cai G P, Li B B, Zhao X, et al. Load parameter prediction of ball mill based on adaptive VMD-Hilbert [J]. Transducer and Microsystem Technologies, 2023, 42(9): 133-136.
- [ 11 ] 张京瑶, 安辉, 邓文字, 等. 基于神经网络的真空泵用驱动电机发热预测[J]. 电机与控制应用, 2025, 52(5): 552-561.
- Zhang J Y, An H, Deng W Y, et al. Heating prediction of drive motors for vacuum pumps based on neural network [J]. Electric Machines & Control Application, 2025, 52(5): 552-561.
- [ 12 ] 陈少霞, 高卓, 姚钢, 等. 基于小波神经网络的六相永磁同步电机高阻连接状态感知策略[J]. 电机与控制应用, 2024, 51(6): 1-11.

- Chen S X, Gao Z, Yao G, et al. Sensing strategy for high resistance connection state of six-phase PMSM based on wavelet neural network [J]. *Electric Machines & Control Application*, 2024, 51(6): 1-11.
- [13] 徐玉珍, 邹中华, 刘宇龙, 等. 基于多尺度卷积神经网络和双注意力机制的V2G充电桩开关管开路故障信息融合诊断[J]. *中国电机工程学报*, 2025, 45(8): 2992-3002.
- Xu Y Z, Zou Z H, Liu Y L, et al. Information fusion diagnosis of switching tube open-circuit fault in V2G charging piles based on multi-scale convolutional neural network and dual-attention mechanism [J]. *Proceedings of the CSEE*, 2025, 45(8): 2992-3002.
- [14] 鄢少彪, 张可可. 一种基于卷积神经网络的电缆故障识别方法[J]. *邮电设计技术*, 2025(8): 81-86.
- Yan S B, Zhang K K. A cable fault identification method based on convolutional neural network [J]. *Designing Techniques of Posts and Telecommunications*, 2025(8): 81-86.
- [15] 谢乐, 杨浙, 刘东. 基于多头注意力机制和门控循环单元神经网络的居民充电桩容量预测[J]. *电机与控制应用*, 2024, 51(3): 21-29.
- Xie L, Yang Z, Liu D. Residential charging station capacity prediction based on multi-head attention and gated recurrent unit neural network [J]. *Electric Machines & Control Application*, 2024, 51(3): 21-29.
- [16] 赵毅涛, 李钊, 刘兴龙, 等. 融合卷积神经网络和注意力机制的负荷识别方法[J]. *电力工程技术*, 2025, 44(1): 227-235.
- Zhao Y T, Li Z, Liu X L, et al. Load recognition method based on convolutional neural network and attention mechanism [J]. *Electric Power Engineering Technology*, 2025, 44(1): 227-235.
- [17] Niu Z Y, Zhong G Q, Yu H. A review on the attention mechanism of deep learning [J]. *Neurocomputing*, 2021, 452: 48-62.
- [18] 陈巨龙, 李震, 朱永清, 等. 基于深度神经网络的斜坡式重力储能系统质量块抓取装置控制方法[J]. *电机与控制应用*, 2023, 50(11): 37-45.
- Chen J L, Li Z, Zhu Y Q, et al. Control method of mass block grasping device of slope gravity energy storage system based on deep neural network [J]. *Electric Machines & Control Application*, 2023, 50(11): 37-45.
- [19] Liu Y L, Jin T, Mohamed M A. A novel dual-attention optimization model for points classification of power quality disturbances [J]. *Applied Energy*, 2023, 339: 121011.
- [20] 孙二杰, 张奇丰, 王德清. 基于轻量级YOLOv8的变电站设备缺陷检测[J]. *计算机与现代化*, 2025(11): 65-70+79.
- Sun E J, Zhang Q F, Wang D Q. Substation equipment defect detection based on lightweight YOLOv8 [J]. *Computer and Modernization*, 2025(11): 65-70+79.
- [21] 贺江涛, 姜媛媛. 融合多尺度时频域特征的电力电子电路软故障诊断[J]. *电机与控制应用*, 2025, 52(7): 788-799.
- He J T, Jiang Y Y. Fusion of multi-scale time-frequency domain features for soft fault diagnosis of power electronic circuits [J]. *Electric Machines & Control Application*, 2025, 52(7): 788-799.
- [22] 郗阳. 变电站继电保护系统故障模拟试验及智能故障定位方法研究[D]. 南京: 南京理工大学, 2021.
- Li Y. Research on experiment and intelligent fault location for relay protection system in subtraction [D]. Nanjing: Nanjing University of Science and Technology, 2021.
- [23] 吴佳, 刘析远, 陈森朋. 基于元学习的超参数优化方法综述[J]. *哈尔滨工业大学学报*, 2026, 58(1): 77-91.
- Wu J, Liu X Y, Chen S P. Survey on meta-learning-based hyperparameter optimization [J]. *Journal of Harbin Institute of Technology*, 2026, 58(1): 77-91.
- [24] 许瀚文. 基于深度学习的MVB网络健康评估和故障诊断方法研究[D]. 大连: 大连交通大学, 2025.
- Xu H W. Research on MVB network health assessment and fault diagnosis method based on deep learning [D]. Dalian: Dalian Jiaotong University, 2025.
- [25] 杨勇, 石寰宇, 李传, 等. 人工智能应用于电力电缆局部放电诊断的研究进展[J]. *高电压技术*, 2026, 52(2): 868-883.
- Yang Y, Shi H Y, Li C, et al. Research progress on artificial intelligence for partial discharge diagnosis in

- power cables [J]. High Voltage Engineering, 2026, 52(2): 868-883.
- [26] 徐修贤, 高兵, 吴泽伟, 等. 基于增强特征传递结构神经网络的超磁致伸缩电声换能器输出特性分析[J]. 电工技术学报, 2025, 40(23): 7449-7461.  
Xu X X, Gao B, Wu Z W, et al. Analysis of output characteristics of giant magnetostrictive electroacoustic transducer based on enhanced feature transfer structure neural network [J]. Transactions of China Electrotechnical Society, 2025, 40(23): 7449-7461.
- [27] 丁卓, 张和生, 汤映琮, 等. 基于多尺度特征融合卷积神经网络的牵引电机转子断条故障诊断方法[J]. 电工技术学报, 2026, 41(2): 512-526.  
Ding Z, Zhang H S, Tang Y C, et al. The fault diagnosis method of traction motor broken rotor bar based on multi-scale feature fusion convolutional neural networks [J]. Transactions of China Electrotechnical Society, 2026, 41(2): 512-526.
- [28] 邱欢, 郭俊杉, 王浩, 等. 基于蚁群优化双向长短期记忆神经网络的中长期电网尖峰负荷预测[J]. 电网与清洁能源, 2025, 41(6): 137-143.  
Qiu H, Guo J S, Wang H, et al. Mid-to-long-term peak load forecasting based on ant colony optimization bidirectional long short-term memory neural networks [J]. Power System and Clean Energy, 2025, 41(6): 137-143.
- [29] 陈佳文. 基于深度学习的 XLPE 电缆局部放电模式识别方法研究[D]. 武汉: 武汉纺织大学, 2025.  
Chen J W. Research on partial discharge pattern recognition method for XLPE cables based on deep learning [D]. Wuhan: Wuhan Textile University, 2025.

---

收稿日期:2025-11-26

收到修改稿日期:2026-01-14

作者简介:

李陈莹(1990—),女,高级工程师,研究方向为电力电缆运行评价、输电线路防灾减灾, chlichenying@163.com;

\* 通信作者:吴淑群(1988—),男,博士,教授,研究方向为高电压与放电等离子体技术, wushuqun@nuaa.edu.cn。