

主动谐波注入增强的地铁直流牵引网 CNN-LSTM 短路故障定位

陈熙昊¹, 汪琦¹, 张家辉¹, 张映壮², 卢闻州²

(1. 宁波市轨道交通集团有限公司智慧运营分公司, 浙江 宁波 315100; 2. 江南大学自动化与智能科学学院, 江苏 无锡 214122)

摘要: 针对地铁直流牵引网短路故障定位中, 牵引电流易受列车启动、负荷波动及整流纹波等系统谐波干扰, 导致故障区段特征辨识度不足的问题, 提出一种主动谐波注入增强的卷积神经网络 (CNN) 与长短期记忆网络 (LSTM) 融合的故障定位方法, 弥补传统被动采集电流特征辨识度低的固有缺陷。该方法通过向牵引网主动注入谐波以增强输入特征中的故障辨识信息, 经经验小波变换提取注入谐波响应作为定位特征, 利用 CNN 提取局部波形特征, 结合 LSTM 学习时序变化信息, 实现列车启动状态与故障区段的分类识别。结果表明, 与原始牵引电流输入相比, 主动注入谐波响应输入下各模型定位性能均明显提升, 其中, 在 7 类识别工况共 630 组测试样本上, CNN-LSTM 模型的准确率和 F1 分数均达到 98.03%, 能够有效区分列车启动状态与短路故障, 并实现不同故障区段的准确识别, 所提方法为地铁直流牵引网短路故障区段定位提供了一种有效思路。

关键词: 地铁直流牵引网; 主动谐波注入; 特征增强; 短路故障定位; CNN-LSTM

中图分类号: U231

文献标志码: A

Active Harmonic Injection-Enhanced CNN-LSTM for Short-Circuit Fault Location in Metro DC Traction Networks

Chen Xihao¹, Wang Qi¹, Zhang Jiahui¹, Zhang Yingzhuang², Lu Wenzhou²

(1. Smart Operation Branch, Ningbo Rail Transit Group Co., Ltd., Ningbo 315100, China; 2. School of Automation and Intelligent Science, Jiangnan University, Wuxi 214122, China)

Abstract: To address the insufficient discriminability of fault-section features caused by disturbances such as train starting, load fluctuations, and rectifier ripple in metro direct current (DC) traction networks, an active harmonic injection-enhanced fault location method integrating a convolutional neural network (CNN) with a long short-term memory (LSTM) network is proposed, overcoming the inherent limitation of insufficient fault-feature discriminability associated with conventional passive traction-current acquisition. Harmonic signals are actively injected into the traction network to enhance the fault-discriminative information contained in the input features. The injected harmonic response is then extracted using the empirical wavelet transform and employed as the fault-location feature. The CNN is used to extract local waveform features, while the LSTM is introduced to learn temporal variation characteristics, thereby enabling the classification of train-starting conditions and different fault sections. The results show that, compared with the original traction current input, using the harmonic response induced by active injection as the input significantly improves the fault-location performance of all evaluated models. Among them, the CNN-LSTM model achieves both an accuracy and an F1-score of 98.03% on a test set of 630 samples covering seven classification categories, effectively distinguishing train-starting conditions from short-circuit faults and accurately identifying different fault sections. The proposed method provides an effective approach for short-circuit fault-section location in metro DC traction networks.

Key words: metro DC traction network; active harmonic injection; feature enhancement; short-circuit fault location; CNN-LSTM

地铁作为城市的核心交通基础设施，其安全运行关乎公共安全与城市交通运营效能^[1]。地铁直流牵引网作为动力核心，其短路故障易引发瞬时大电流冲击，导致设备损毁、接触网失效等严重后果^[2]。因此，研究地铁直流牵引网短路故障定位方法，对保障地铁安全稳定运营具有重要意义。现有电力线路故障定位典型方法包括故障分析法、阻抗法和行波法等^[3-5]，通过分析故障后线路原始电气量变化特征来实现故障定位。对于地铁直流牵引网线路中的原始牵引电流，其中不仅包含故障信息，还叠加了负荷波动、整流纹波、线路噪声及过渡电阻等扰动分量，使得故障特征易被非故障分量遮盖。若仅依赖原始牵引电流的电气量采用典型方法进行定位，易导致阻抗误差增大、行波波头难以识别以及保护阈值难以整定，降低定位准确性。

为削弱原始牵引电流中非故障分量对定位特征的影响，文献[6-8]提出基于特征波能量分析的地铁直流牵引网保护方法，通过提取特征波能量变化实现短路故障判别。相比直接利用原始牵引电流信号，特征谐波能够突出故障响应差异，降低非故障分量对故障特征的干扰，为地铁牵引网的故障定位提供了更具辨识度的特征量^[9-10]。然而，被动特征提取的方式，其固有特征谐波幅值受故障距离、过渡电阻及线路衰减影响较大，易出现幅值较小使不同区间特征重叠，同样出现故障辨识度不足的问题，无法稳定表征故障位置差异。为进一步增强故障特征辨识度，文献[11]采用主动注入特征谐波的方法，实现了城轨直流牵引网短路故障判别与定位；文献[12]提出了主动注入特征谐波并结合小波能量分析的方法，通过增强特征差异实现地铁牵引网中短路故障与列车启动电流的快速区分。通过主动注入特征信号增强故障响应差异，能够为复杂工况下的故障定位提供更稳定的特征^[13-15]。与此同时，基于人工智能的技术已逐步应用于电力系统故障分析与定位^[16-19]。

基于此，提出一种主动谐波注入增强的地铁直流牵引网 CNN-LSTM 短路故障定位方法，其中 CNN 为卷积神经网络(convolutional neural network, CNN)，LSTM 为长短期记忆网络(long short-term memory)；利用主动谐波注入增强模型输入中的故障辨识信息，获取注入频段下的谐波响应并将其作为模型输入，实现列车启动状态与不同短路故障区段的分类识别，为地铁直流牵引网短路故障定位提供一种新思路。

1 地铁直流牵引网牵引电流的局限性

地铁直流牵引网通常由牵引变电站、馈线、接触网、列车负荷、走行轨及回流线等构成，如图 1 所示。牵引变电站将中压交流电经降压整流后变换为直流电，并通过接触网向列车供电；牵引电流经走行轨和回流线返回牵引变电所，形成完整的供电回路。




图 1 地铁直流牵引系统的结构图

Fig.1 Structure diagram of the metro DC traction system

牵引电流能够反映牵引网中的电气变化,如短路故障、列车启动及负荷波动等工况均会在电流波形中产生变化。然而,牵引电流波形是列车运行状态、牵引负荷变化、整流纹波、线路参数、过渡电阻及测量噪声等多因素共同作用下形成的复合波形。非故障成分的叠加削弱了故障位置的特征差异,使得基于牵引电流的故障定位方法存在辨识度不足和稳定性受限的问题,牵引网短路故障定位需要更具故障辨识度的输入特征。

基于此,通过向牵引网注入特征谐波信号,获取注入频段下的故障响应,并通过基于人工智能的 CNN-LSTM 来进一步建立故障响应与故障位置间的映射关系实现故障定位。注入设备选用单相隔离型逆变器,通过串联电压源方式主动注入特征谐波,如图 1 中的逆变器 A、B 所示。

2 主动谐波注入增强的 CNN-LSTM 方法

2.1 主动谐波注入的启动与参数

牵引网发生短路故障时,牵引电流会在短时间内快速上升,表现出明显的电流突变特征,因此只需要牵引网牵引电流变化率大于整定值时,才启动特征谐波注入,启动判据为

$$\left| \frac{di(t)}{dt} \right| \geq D_{\text{set}} \quad (1)$$

式中: $i(t)$ 为牵引电流, D_{set} 为注入启动整定值,取 $D_{\text{set}} = KI_N$ (A/ms), I_N 为牵引网额定电流,整定系数 K 取 0.05。

在谐波注入参数选择上:① 频率,注入谐波应避开整流机组主要固有谐波频段,并兼顾工频扰动与高频线路衰减问题^[11],因此可以选择非 6 倍频偶数次谐波中的 10 次谐波(500 Hz);② 幅值,结合 GB/T 10411—2025^[20]对 1 500 V 直流牵引供电系统电压范围的要求,因此可以选择注入谐波电压幅值为 100 V^[11]。需要注意的是,注入后直流牵引网电压仍需处于允许波动范围内,即需保证牵引网电压质量下注入合理的特征谐波。

2.2 注入谐波响应的模型输入特征提取

谐波注入后,牵引电流中还叠加了注入谐波在牵引网中的响应成分。为分离此响应成分,采用经验小波变换(empirical wavelet transform, EWT),根据频谱分布自适应划分频带,将牵引电流分解为若干具有不同频带范围的模态分量^[21],得到注入特征谐波响应分量 $i_h(t)$ 为

$$i_h(t) = \text{EWT}_{k_h}[i(t)] \quad (2)$$

式中: h 表示注入目标谐波, k_h 表示 EWT 分解中包含该注入谐波频率的模态序号, $\text{EWT}_{k_h}[\cdot]$ 表示经验小波变换中第 k_h 个模态的提取运算;不同故障区段下线路等效阻抗和故障距离不同, $i_h(t)$ 在幅值和波形轮廓上呈现差异。将提取到的注入谐波响应序列作为 CNN-LSTM 输入特征,用于后续故障定位,可以实现故障特征的增强,提升故障定位的准确率。

2.3 主动谐波注入增强的 CNN-LSTM 模型

构建的主动谐波注入增强的 CNN-LSTM 故障定位模型,其结构如图 2 所示,以注入谐波响应序列作为输入,通过 CNN 层提取局部波形变化及短时响应特征,再利用 LSTM 层学习特征序列的时间关联关系,从而建立注入谐波响应与故障区段之间的非线性映射。




图 2 主动谐波注入增强的 CNN-LSTM 模型结构

Fig.2 Architecture of the active harmonic injection-enhanced CNN-LSTM model

图 2 中的 CNN 层对输入序列进行逐层特征提取和降维,形成具有时序排列关系的局部特征序列;LSTM 层进一步融合各时间步之间的动态关联信息,最后由全连接层和 Softmax 层输出定位结果,并通过丢弃率为 0.1 的 Dropout 层抑制模型过拟合。模型主要结构参数如表 1 所示。

表 1 CNN-LSTM 模型结构参数
Tab.1 Structural parameters of the CNN-LSTM model

网络模块	核大小	步长	通道数/ 节点数	输出大小
输入层	—	—	1	2000×1
Conv1-BN-ReLU	32×1	1	64	2000×64
Max pooling1	4×1	2	64	1000×64
Conv2-BN-ReLU	16×1	1	32	1000×32
Max pooling2	4×1	2	32	500×32
Conv3-BN-ReLU	8×1	1	16	500×16
Max pooling3	4×1	2	16	250×16
LSTM1	—	—	64	250×64
LSTM2	—	—	32	1×32

注:“—”表示该网络层不涉及相应参数;Conv 表示卷积层(convolutional layer),BN 表示批量归一化(batch normalization),ReLU 表示修正线性单元(rectified linear unit),Max pooling 表示最大池化层(max pooling layer)

3 仿真模型与数据集构建

3.1 地铁直流牵引网仿真模型搭建

为验证所提主动谐波注入增强的 CNN-LSTM 故障定位方法,基于 MATLAB/Simulink 搭建如图 1 所示地铁直流牵引网仿真模型,并模拟不同列车位置下的启动、正常牵引运行及不同过渡电阻下的金属性与非金属性短路故障三类典型工况。其中,正常牵引运行工况用于表征牵引负荷相对稳定、牵引网未发生短路故障时的正常供电状态。

仿真参数参考某地铁线路设置:线路全长 39.5 km,设有 14 座牵引变电所,取相邻变电站平均间距 3 km 作为仿真区间长度;其他线路参数设置为:接触网和走行轨的电阻率和电感率分别为 $r_1 = 28\text{m}\Omega/\text{km}$ 、 $l_1 = 2.67\text{mH}/\text{km}$ 和 $r_2 = 9.5\text{m}\Omega/\text{km}$ 、 $l_2 = 0.16\text{mH}/\text{km}$;考虑到实际牵引网短路故障可能因电弧、污秽及接触状态等因素产生附加过渡电阻,为考察所提方法在不同故障接触条件下的适应性,将短路电阻设置为 0~10 Ω 。通过改变故障位置、短路电阻和列车运行状态生成仿真样本,为后续构建注入谐波响应提取和故

障定位数据集奠定基础。

3.2 主动谐波注入响应的提取

为验证 2.2 节所述注入谐波响应提取方法的有效性,对主动谐波注入后的牵引电流进行 EWT 分解,根据 2.1 节设置的 10 次注入谐波(500 Hz),选取分解结果中频带包含 500 Hz 的模态分量,获得目标谐波响应序列,原始牵引电流与提取后的注入谐波响应分别如图 3 和图 4 所示。




图 3 牵引电流

Fig. 3 Traction network current

由图 3 中可以看到,列车启动和短路故障均会引起牵引电流快速变化,其中短路电流突变更明显。牵引电流同时包含直流和系统谐波,各频率成分相互叠加,故障特征易与非故障扰动混叠,直接作为故障定位模型输入时特征辨识度不足。

由图 4 中可以看到,提取后的谐波响应呈现明显的周期性振荡特征,局部放大波形的振荡周期约为 0.002 s,对应频率约为 500 Hz,与设定的 10 次谐波注入频率一致,表明 EWT 能够有效提取目标频段的谐波响应。相比原始牵引电流,谐波响应波形中直流分量和非注入频段干扰明显减弱,故障特征更加突出。因此,主动注入谐波响应将为后续 CNN-LSTM 模型的输入样本生成提供坚实基础。




图 4 主动谐波注入下谐波响应提取结果

Fig.4 Harmonic response extraction results under active harmonic injection

3.3 数据集构建与训练

基于 3.1 节的仿真模型,选取列车正常启动、不同故障距离下的短路故障两类核心工况,构建用于区分列车启动扰动与短路故障并识别不同故障区段的数据集。以牵引变电站 A 为距离基准,定义故障距离为 d ,按 0.5 km 间隔划分为 6 个短路故障区段,连同列车启动状态形成 7 类工况标签,如表 2 所示。

每类工况构建 300 组样本,共构建 2 100 组样本作为 CNN-LSTM 模型输入。数据集按 7:3 随机划分为训练集和测试集,训练参数在各组对比实验中保持一致,训练轮数设为 100,批处理大小设为 32,初始学

习率设为 0.001，模型采用 Adam 优化算法进行训练，损失函数为交叉熵损失函数。

表 2 故障定位工况标签及样本分布
Tab.2 Fault location labels and sample distribution

标签	工况类别	对应状态或故障 区段	样本数量
0	列车启动	非故障启动状态	300
1	故障区段 1	$0 < d \leq 0.5$ km	300
2	故障区段 2	$0.5 < d \leq 1.0$ km	300
3	故障区段 3	$1.0 < d \leq 1.5$ km	300
4	故障区段 4	$1.5 < d \leq 2.0$ km	300
5	故障区段 5	$2.0 < d \leq 2.5$ km	300
6	故障区段 6	$2.5 < d \leq 3.0$ km	300

4 结果与分析

4.1 对比分析

为验证主动谐波注入增强的 CNN-LSTM 方法的有效性，并分析输入特征和网络结构对定位性能的影响，分别以原始牵引电流和主动注入谐波响应作为模型输入，在相同的数据集划分和训练参数下，对 CNN、LSTM 及 CNN-LSTM 模型进行多次重复实验，所得平均故障定位性能结果如表 3 所示。

由表 3 可知，在网络结构相同的条件下，采用主动注入谐波响应作为输入时，三种模型的定位性能均明显优于原始牵引电流输入。CNN、LSTM 和 CNN-LSTM 模型的准确率分别由 66.10%、33.90%和 68.00% 提升至 96.44%、59.90%和 98.03%，分别提升了 30.34%、26%和 30.03%；对应的 F1 分数分别由 65.80%、28.89%和 66.67%提升至 96.47%、59.16%和 98.03%，分别提升了 30.67%、30.27%和 31.36%。由此可见，主动谐波注入能够提高模型输入中故障区段的辨识度，从而有效改善了对应模型的故障定位性能。

表 3 不同输入特征下模型故障定位性能对比
Tab.3 Comparison of model location performance under different input features

模型	输入特征	准确率/%	精确率/%	召回率/%	F1 分数/%
CNN	原始牵引 电流	66.10	69.17	66.10	65.80
LSTM		33.90	38.80	33.90	28.89
CNN-LSTM		68.00	67.61	68.00	66.67
CNN	主动注入 谐波响应	96.44	96.74	96.44	96.47
LSTM		59.90	64.57	59.90	59.16
CNN-LSTM		98.03	98.09	98.03	98.03

特别地，主动谐波注入增强的 CNN-LSTM 模型具有最优的性能，优于单一的主动谐波注入增强的 CNN 和 LSTM 模型，这说明局部特征提取（CNN）与时序关联建模（LSTM）的结合有利于提高故障区段定位效果。

4.2 主动谐波注入增强的 CNN-LSTM 效果

为进一步展示主动谐波注入增强的 CNN-LSTM 模型的故障定位效果，选取其中一次训练与测试结果进行分析，其准确率与损失值变化曲线、混淆矩阵和评价指标结果分别如图 5、图 6 和表 4 所示。

从图 5 中可以看到，随着迭代次数增加，模型准确率逐渐上升，损失值持续下降并趋于稳定，这表明

CNN-LSTM 方法能够从主动注入谐波响应的输入中提取有效的故障特征，且训练过程具有良好的收敛性。




图 5 CNN-LSTM 准确率与损失值变化曲线

Fig.5 Variation curves of CNN-LSTM accuracy and loss values

从图 6 和表 4 中都可以看出，CNN-LSTM 模型具有较好的识别效果：1）能够准确区分列车启动状态与短路故障，降低启动电流与故障电流特征相似所造成的误判；2）能够对近、中、远距离的不同故障区段均具有较好的识别效果，这说明所提主动谐波注入增强的 CNN-LSTM 方法能够实现牵引网短路故障的有效故障区段定位。




图 6 混淆矩阵

Fig. 6 Confusion matrix

表 4 评估指标分析

Tab.4 Analysis of Evaluation Metrics

类别	准确率/%	精确率/%	召回率/%	F1 分数/%
启动	100.00	100.00	100.00	100.00
区域 1[0-0.5]km	95.56	100.00	95.56	97.73
区域 2[0.5-1.0]km	100.00	95.74	100.00	97.83
区域 3[1.0-1.5]km	100.00	100.00	100.00	100.00
区域 4[1.5-2.0]km	97.78	100.00	97.78	98.88
区域 5[2.0-2.5]km	96.67	97.75	96.67	97.21
区域 6[2.5-3.0]km	100.00	96.77	100.00	98.36

综上，所提主动谐波注入增强的 CNN-LSTM 方法实现了列车启动状态及不同故障区段的有效识别，

验证了所提方法在地铁直流牵引网短路故障定位中的有效性和优越性。

5 结论

针对地铁直流牵引网原始牵引电流受列车启动、负荷波动及整流纹波等因素影响,导致故障辨识度不足的问题,提出一种主动谐波注入增强的地铁直流牵引网 CNN-LSTM 故障定位方法。通过向牵引网主动注入谐波,提取注入频段谐波响应并将其作为模型输入,并通过 CNN-LSTM 融合局部波形特征与时序变化信息,实现列车启动状态与不同短路故障区段的有效识别。

1) 采用主动注入谐波响应作为输入时,单一 CNN、单一 LSTM 和 CNN-LSTM 模型的定位性能均明显优于采用原始牵引电流作为输入,其中, CNN-LSTM 模型的准确率和 F1 分数均达到 98.03%,能够有效区分列车启动状态与短路故障,并对近、中和远距离故障区段都能实现有效识别。

2) 主动谐波注入增强的地铁直流牵引网 CNN-LSTM 能够增强模型输入中的故障辨识信息,验证了所提方法在地铁直流牵引网短路故障区段定位中的有效性。

此外,所提方法由被动获取故障特征转向主动施加特征激励,增强不同工况下故障响应特征的辨识度,其技术思路对其他故障类型及类似电气系统中的故障识别与定位具有一定的借鉴意义。

参考文献:

- [1] FANG F, WANG H T, CHEN K, et al. Risk Analysis of Chongqing Urban Rail Transit Network[J]. Journal of Loss Prevention in the Process Industries, 2020, 66: 104182.
- [2] ZHANG H X, WANG X D, XIANG B, et al. Interrupting characteristics of a DC combined apparatus for rail transit systems[J]. IET Generation, Transmission & Distribution, 2022, 16: 3441-3450.
- [3] 秦烨焱, 王宾, 潘本仁, 等. 基于时域阻抗法的 35 kV 配电线路相间短路故障测距[J]. 电力系统保护与控制, 2025, 53(16): 169-176.
- [4] QIN Y Y, WANG B, PAN B R, et al. Phase-to-phase short-circuit fault location in 35 kV distribution networks based on time-domain impedance method[J]. Power System Protection and Control, 2025, 53(16): 169-176.
- [5] CHANG Z X, LIU Y K, SUN Y W, et al. Fault Location in Distribution Networks With Multi-Lateral Branches Based on Time-Domain Difference[J]. Sustainable Energy Technologies and Assessments, 2026, 91: 105050.
- [6] SHI S X, LEI A Y, HE X, et al. Travelling waves-based fault location scheme for feeders in power distribution network[J]. The Journal of Engineering, 2018, 2018(15): 1326-1329.
- [7] 刘炜, 李思文, 王竞, 等. 基于 EWT 能量熵的直流短路故障辨识[J]. 电力自动化设备, 2020, 40(2): 149-154.
- [8] LIU W, LI S W, WANG J, et al. Identification of DC short circuit fault based on EWT energy entropy[J]. Electric Power Automation Equipment, 2020, 40(2): 149-154.
- [9] 王岳新, 狄箫, 陈梦舟, 等. 基于 24 次谐波电流小波能量的地铁直流接触网短路保护方法研究[J]. 铁道技术监督, 2025, 53(2): 53-58.
- [10] WANG Y X, DI X, CHEN M Z, et al. A protection method based wavelet energy on of 24th harmonic current[J]. Railway Quality Control, 2025, 53(2): 53-58.
- [11] 徐小林, 张福生, 胡源, 等. 基于多尺度能量分析法的直流馈线保护算法改进[J]. 石家庄铁道大学学报(自然科学版), 2017, 30(3): 71-76.
- [12] XU X L, ZHANG F S, HU Y, et al. Improvement of DC Feeder Protection Algorithm Based on Multi-scale Energy Analysis Method[J]. Journal of Shijiazhuang Tiedao University (Natural Science Edition), 2017, 30(3): 71-76.
- [13] 苏煜, 汤士明, 张子扬. 基于特征谐波的地铁直流馈线保护方法[J]. 河北电力技术, 2023, 42(2): 61-67.
- [14] SU Y, TANG S M, ZHANG Z Y. DC Feeder Protection Method for Subway Based on Characteristic Harmonic[J]. Hebei Electric Power, 2023, 42(2): 61-67.
- [15] 苏煜, 汤士明, 宋金孺. 提取 24 次谐波的凯赛窗算法研究[J]. 青海电力, 2022, 41(S1): 32-36.
- [16] SU Y, TANG S M, SONG J R. Research on Kaiser Window Algorithm for Extracting the 24th Harmonic[J]. Qinghai Electric Power, 2022, 41(S1): 32-36.
- [17] 卢闻州, 陈梦舟, 王祥州. 基于特征谐波的城轨直流牵引网短路故障保护和定位方法[J]. 中国电机工程学报, 2026,

46(11): 4502-4513.

LU W Z, CHEN M Z, WANG X Z. Short-circuit Fault Protection and Location Method for Urban Rail DC Traction Networks Based on Characteristic Harmonics[J]. Proceedings of the CSEE, 2026, 46(11): 4502-4513.

- [12] 俞益, 吴德明, 孙海东, 等. 储能式地铁牵引系统主动注入式保护方法研究[J]. 电气自动化, 2025, 47(4): 9-12.

YU Y, WU D M, SUN H D, et al. Research on active injection protection method for energy storage metro traction system[J]. Electrical Automation, 2025, 47(4): 9-12.

- [13] 曹赋禄, 赵晋斌, 潘超, 等. 基于 DFFT 的低压直流线路主动式接地故障定位方法[J]. 中国电力, 2023, 56(4): 184-191.

CAO F L, ZHAO J B, PAN C, et al. An Active Ground Fault Location Method for Low-Voltage DC Lines Based on DFFT[J]. Electric Power, 2023, 56(4): 184-191.

- [14] 刘子奕, 贾科, 姚昆鹏, 等. 基于主动注入的柔性直流配电网故障定位[J]. 电力系统保护与控制, 2023, 51(18): 21-30.

LIU Z Y, JIA K, YAO K P, et al. An active converter injection-based fault location method for a flexible DC distribution network[J]. Power System Protection and Control, 2023, 51(18): 21-30.

- [15] 王伟, 帅智康, 李杨, 等. 基于固态断路器主动注入式直流故障测距方法[J]. 电工技术学报, 2024, 39(8): 2360-2370.

WANG W, SHUAI Z K, LI Y, et al. Active Injection DC Fault Location Method Based on Solid State Circuit Breaker[J]. Transactions of China Electrotechnical Society, 2024, 39(8): 2360-2370.

- [16] 和敬涵, 罗国敏, 程梦晓, 等. 新一代人工智能在电力系统故障分析及定位中的研究综述[J]. 中国电机工程学报, 2020, 40(17): 5506-5516.

HE J H, LUO G M, CHENG M X, et al. A research review on application of artificial intelligence in power system fault analysis and location[J]. Proceedings of the CSEE, 2020, 40(17): 5506-5516.

- [17] DU G F, LIU N, ZHANG D L, et al. Grounding Fault Diagnosis of Running Rails Based on a Multi-Scale One-Dimensional Convolutional Neural Network in a DC Subway System[J]. Urban Rail Transit, 2024, 10(3): 263-279.

- [18] GUO M F, YANG N C, CHEN W F. Deep-Learning-Based Fault Classification Using Hilbert-Huang Transform and Convolutional Neural Network in Power Distribution Systems[J]. IEEE Sensors Journal, 2019, 19(16): 6905-6913.

- [19] 韦宝泉, 刘龙平, 邓芳明, 等. 基于 FedGSC 和 RT-DETR 的电力设备缺陷检测技术[J]. 华东交通大学学报, 2026, 43(2): 104-114.

WEI B Q, LIU L P, DENG F M, et al. Research on Defect Detection Technology for Power Equipment Based on Efficient Federated Learning and RT-DETR[J]. Journal of East China Jiaotong University, 2026, 43(2): 104-114.

- [20] GB/T 10411—2025 城市轨道交通直流牵引供电系统[S].

GB/T 10411—2025 DC electric traction systems of urban rail transit[S].

- [21] 李阳, 路鹏, 朱伯涛, 等. 基于经验小波变换和改进卷积神经网络的变压器故障诊断方法[J]. 电子设计工程, 2021, 29(8): 140-144.

LI Y, LU P, ZHU B T, et al. Transformer fault diagnosis method based on empirical wavelet transform and improved convolutional neural network[J]. Electronic Design Engineering, 2021, 29(8): 140-144.



第一作者: 陈熙昊 (1989—), 男, 高级工程师, 研究方向为轨道交通供电系统运营管理与技术创新。



通信作者: 卢闻州 (1983—), 男, 副教授, 博士, 硕士生导师, 研究方向为有源配电网保护与控制、电力电子变流控制技术。