

基于 TransTCN 半监督模型的配电网单相 接地故障检测方法研究

邱桂华^{1*}, 郭志燊¹, 邵玉明¹, 刘 剑²

(1. 南方电网 广东佛山供电局, 广东 佛山 528000;

2. 湖南大学设计研究院有限公司, 湖南 长沙 410006)

Research on Single-Phase Grounding Fault Detection Method in Distribution Network Based on TransTCN Semi-Supervised Model

QIU Guihua^{1*}, GUO Zhishen¹, SHAO Yuming¹, LIU Jian²

(1. Guangdong Power Grid Co., Ltd. Foshan Power Supply Bureau, China Southern Power Grid,
Foshan 528000, China;

2. Hu'nan University Design and Research Institute Co., Ltd., Changsha 410006, China)

Abstract: [Objective] The initial feature of single-phase grounding faults in distribution networks is weak, with a low signal-to-noise ratio. Traditional fault detection methods suffer from low detection accuracy and insufficient generalization capability when labeled data samples are limited. To address this issue, this paper proposes a TransTCN semi-supervised collaborative learning framework that integrates Transformer and temporal convolutional network (TCN). [Methods] Firstly, the improved complementary ensemble empirical mode decomposition (ICEEMD) method was employed to perform adaptive mode decomposition on fault zero-sequence current signal, thereby selecting the optimal feature components. Secondly, model training was initialized with a small number of labelled data sample, and the unlabeled dataset expanded through a high-confidence pseudo-label generation mechanism, and combined with a loss function featuring weight-adaptive allocation to achieve iterative optimization of model parameters. Finally, a single-phase grounding fault model for a 10 kV distribution network was constructed using PSCAD. The detection performance of the proposed TransTCN semi-supervised model was validated under varying grounding resistances, initial fault angles, and operational conditions. [Results] Under conditions where labeled data constituted merely 15% of the dataset, the proposed TransTCN semi-supervised model achieved an identification accuracy of 95.31% for weak feature single-

phase grounding fault. [Conclusion] TransTCN semi-supervised model has significant advantages in weak feature extraction and few-sample learning scenarios. It performs well in terms of fault identification accuracy, convergence stability, and cross-condition generalization ability, and has certain engineering application value.

Key words: single-phase grounding fault; Transformer; temporal convolutional network; improved complementary ensemble empirical mode decomposition; weak feature

摘 要: 【目的】配电网单相接地故障初期特征微弱、信噪比较低,传统故障检测方法在标签数据样本有限时存在检测精度低和泛化能力不足的问题。为解决此问题,本文设计了一种融合 Transformer 与时间卷积网络(TCN)的 TransTCN 半监督协同学习框架。【方法】首先,采用改进互补集合经验模态分解(ICEEMD)方法对故障零序电流信号进行自适应模态分解,筛选最优特征分量;然后,通过少量标签数据样本初始化模型训练,并基于高置信度伪标签生成机制扩充无标签数据集,结合权重自适应分配的损失函数实现模型参数迭代优化;最后,基于 PSCAD 构建 10 kV 配电网单相接地故障模型,对所提 TransTCN 半监督模型在不同接地电阻、故障初始角及运行工况下的检测性能进行了验证。【结果】在有标签数据比例仅为 15% 的条件下,所提 TransTCN 半监督模型对弱特征单相接地故障的识别准确率高达 95.31%。【结论】TransTCN 半监督模型在弱特征提取和小样本学习场景下具有明显优势,在故障识别精度、收敛稳定性及跨工况泛化能力等方面均表现良好,具备一定的工程应用价值。

关键词: 单相接地故障;Transformer;时间卷积网络;改进

基金项目:南方电网公司科技项目(GDKJXM20240450)
Technology Project of CSG Co., Ltd (GDKJXM20240450)

互补集合经验模态分解;弱特征

0 引言

配电网的稳定运行是保障用户高质量用电的核心基础,而快速发现并精准识别配电网中的故障则是提升电网保护能力的关键^[1-3]。在航天发射场等对供电可靠性要求极高的关键场景中,实时监测电网运行状态、精准识别配电网故障尤为重要。因此,针对配电网故障检测方法的研究具有重要的工程意义。目前,配电网中的故障可分为大电流故障和弱特征故障两类。大电流故障因其电流幅值较大且特征明显,易于被现有保护系统检测和处理^[4-5]。相比之下,弱特征故障由于电流变化微弱,难以被传统保护设备如电流保护器或熔断器有效识别,可能导致保护动作延迟或失效,从而可能引发严重的电力系统安全问题^[6-8]。因此,探索一种能够高效识别和判断弱特征故障的方法,对于保障配电网的安全运行和满足用户高质量用电需求具有重要价值。

目前,针对配电网弱特征故障检测的方法主要分为三类:基于解析模型的方法、基于信号分析的方法和基于数据驱动的方法^[9-10]。

基于解析模型的方法通过对比系统测量参量和系统动态模型参量间的残差区分弱特征故障^[11]。如文献[12]采用加权格兰杰因果关系来分析系统扰动期间母线间因果关系,通过最优同步相量测量判断智能电网中的弱特征故障,但该方法模型复杂,难以应对实时性要求高的故障检测。文献[13]利用复杂事件处理技术建立数据与信息间的逻辑关系实现故障诊断,但该方法逻辑推理和判断过程对算法的要求较高,泛化能力较差,难以大面积推广。

基于信号分析的方法主要通过对故障信号进行快速傅里叶变换(Fast Fourier Transform, FFT)、S变换或经验模态分解(Empirical Mode Decomposition, EMD)等时频域处理,提取故障的时频特性,从而实现故障检测^[14-19]。这些技术能够有效分离并突出信号中的突变和瞬态特征,但计算复杂度较高,难以满足电网对实时性的需求。

随着数据采集与监视控制系统在电网中的广泛部署,基于数据驱动的方法逐渐成为研究热点。

该方法通过人工智能技术,基于历史数据进行故障识别,无需预置阈值,泛化能力强^[20],主要包括无监督学习和有监督学习两类。无监督学习方法适用于标签数据不足的场景。文献[21]利用深度置信网络进行无监督学习,获得了较好的检测效果。文献[22]使用K近邻算法处理电流和电压信号。然而,无监督学习方法缺乏先验知识支持,学习过程较为繁琐,且检测性能有限。有监督学习方法通过标签数据优化模型,通常能达到较优的检测效果。文献[23-24]采用多级支持向量机(Support Vector Machine, SVM)和遗传算法优化SVM进行故障识别,但SVM作为单一分类器,其学习能力存在局限性。文献[25]结合粒子群优化算法与贝叶斯分类器进行故障检测,但该方法在处理高维数据时表现受限。文献[26]利用长短期记忆(Long Short-Term Memory, LSTM)网络结合注意力机制进行故障检测,但易出现过拟合。现有有监督学习方法通常依赖人工进行特征提取,且模型复杂度较高。

为弥补现有方法的不足,本文提出了一种基于Transformer与时间卷积网络(Temporal Convolutional Network, TCN)协同训练的TransTCN半监督深度学习模型。该模型通过TCN挖掘局部特征,结合Transformer获取全局特征,两者协同优化以提高弱特征故障检测的精度。在优化过程中,利用半监督学习方法生成伪标签和正向反馈机制持续精进模型,提升对未标记数据的辨识能力。基于PSCAD平台构建了10 kV辐射配电网模型,模拟弱特征故障,采集零序电流数据,采用改进互补集合经验模态分解(Improved Complementary Ensemble EMD, ICEEMD)算法提取特征。最后,进行TransTCN半监督深度学习模型的训练与验证。

1 故障机理分析

一般中低压配电网线路故障中约80%为单相接地故障^[27],具体分为单相低阻接地故障和单相高阻接地故障。

1.1 单相低阻接地故障

图1为单相低阻接地故障稳态示意图。其中,线路二A相发生单相低阻接地故障,线路一为正常线路。图1中, C_{01} 、 C_{02} 分别为线路一、线

路二对地电容; i_{01} 、 i_{02} 分别为线路一、线路二零序电流。可见,在中性点不接地系统和中性点经消弧线圈接地系统中,正常线路零序电流与故障线路零序电流均相反。

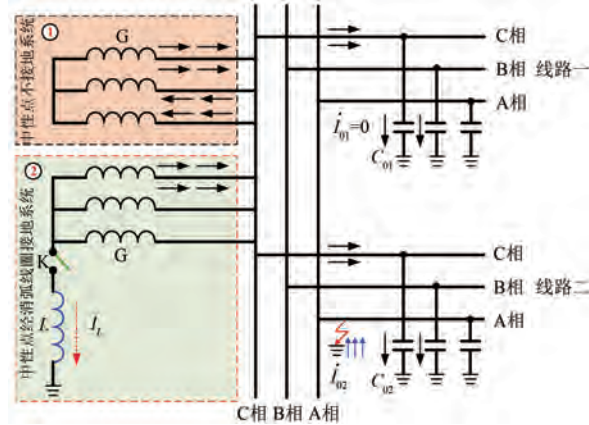


图 1 单相低阻接地故障稳态示意图

Fig. 1 Single-phase low-impedance grounding fault steady-state schematic diagram

当系统发生故障时,暂态电容电流主要由放电电容电流和充电电容电流两部分构成,前者由故障相电压骤降产生,后者由故障相电压骤升产生。

中性点不接地系统发生单相低阻接地故障时的暂态等效电路如图 2(a)所示。由图 2(a)可得:

$$U_m \sin(\omega t + \theta) = L_1 \frac{di_c}{dt} + R_1 i_c + \frac{1}{C_1} \int_0^t i_c dt \quad (1)$$

式中: R_1 、 C_1 、 L_1 和 θ 分别为等效电路电阻、电容、电感和初相角; U_m 为零序电压幅值; i_c 为 A 相故障处容性电流。

中性点经消弧线圈接地系统发生单相低阻接地故障时的暂态等效电路如图 2(b)所示。图中, R_2 、 L_2 和 C_2 分别为等效电路电阻、电感和电容; C_0 为接地电阻; R_{tr} 为过渡电阻; L_p 为消弧线圈电感。




图 2 单相低阻接地故障暂态等效电路图

Fig. 2 Single-phase low-impedance grounding fault transient equivalent circuit diagram

当 $3R_{tr}$ 较小 (0.01Ω) 时,由于暂态过程主要由电容放电主导时, L_p 的响应时间远慢于暂态电流变化,在分析暂态电容电流时可忽略 L_p 对等效电路的影响^[28]。当 $3R_{tr}$ 较大 (100Ω) 时,由于受电容充电速度低的影响,可忽略 R_2 和 L_2 对等效电路的影响。中性点经消弧线圈接地系统中单相低阻接地故障暂态特性受电网初相角、分布参数、消弧线圈容量及过渡电阻的影响。

1.2 单相高阻接地故障

单相高阻接地故障在中性点不接地系统和中性点经消弧线圈接地系统中表现出相似的暂态特性。本文选择具有代表性的中性点经消弧线圈接地系统来分析其暂态特性。单相高阻接地故障暂态等效电路及故障波形如图 3 所示。

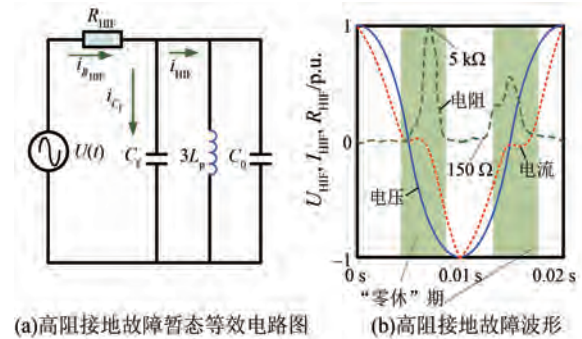


图 3 单相高阻接地故障暂态等效电路图和故障波形

Fig. 3 Single-phase high-impedance grounding fault transient equivalent circuit diagram and fault waveforms

图 3(a) 中, R_{HIF} 为故障阻抗; C_f 为故障点零模分布电容; i_{HIF} 为暂态零模电流; $i_{R_{HIF}}$ 为流经 R_{HIF} 的电流; i_{C_f} 为流经 C_f 的电流。图 3(b) 中,电压过零点处电弧电压维持较低状态,随着故障电弧电离作用逐渐减弱,弧隙电阻处于峰值高阻状态,此时电弧电流接近 0,随着电压逐渐升高,电阻降低,电弧电流增大,电路出现“零休”现象。具体表现趋势为:随着电压变化,故障电弧电流呈现平行于水平轴的畸变现象;故障阻抗出现周期性尖峰阻抗。

2 单相接地故障检测方法

2.1 ICEEMD

EMD 将信号分解为若干本征模态函数 (Intrinsic Mode Function, IMF)^[29],每个 IMF 分解后可描述原始信号的动态特性。假设故障信号

$S(k)$ 由 k 组采集数据构成,利用 EMD 的基本原理对 $S(k)$ 进行分解:

$$S(k) = \sum_{i=1}^j x_i(k) + y_j(k) \quad (2)$$

式中: $x_i(k)$ 为 $S(k)$ 从高到低分解后的第 i 个 IMF; $y_j(k)$ 为分解后的残差信号,其保留了 $S(k)$ 整体的平均趋势。

EMD 虽然能有效处理非线性非平稳信号,但存在模态混叠现象和端点效应。

为避免出现模态混叠现象,集合经验模态分解(Ensemble EMD, EEMD)在故障信号 $S(k)$ 中引入有限幅值白噪声 $Z_m(k)$,以获得含噪信号 $S_m(k)$ ^[30],即:

$$S_m(k) = S(k) + Z_m(k) \quad (3)$$

利用 EMD 对 $S_m(k)$ 进行分解,得到 IMF。再重复上述步骤,即添加高斯白噪声并进行 EMD 分解,得到一组新的 IMF,并对其 M 次试验进行集合平均。最后,通过 EEMD 分解得到最终信号的 IMF。经 EEMD 处理后的第 i 个 IMF 分量 c_i 为

$$c_i = \frac{1}{M} \sum_{m=1}^M x_{m,i} \quad (4)$$

互补集合经验模态分解(Complementary EEMD, CEEMD)为 EEMD 的优化算法,将集中平均数的数量从几百个数量级降低到几十个数量级。对于故障信号尤其是非平稳信号,CEEMD 原理是向原始信号 $S(k)$ 加入 u 组正、负相反的不同量白噪声信号,对去噪后的信号进行 EMD 分解,然后对分解后的 IMF 组取平均值。最后对 k 组 IMF 取平均值,即为最终的 IMF 分量,即:

$$\mu_i = \frac{1}{2M} \sum_{m=1}^M (x_{i,m}^+ + x_{i,m}^-) \quad (5)$$

式中: $x_{i,m}^+$ 和 $x_{i,m}^-$ 分别为对 $S_m^+(k)$ 和 $S_m^-(k)$ 应用 EEMD 得到的信号; μ_i 为经 CEEMD 处理得到的第 i 个 IMF 分量。

CEEMD 分解过程中产生的 IMF 分量个数存在较大差异,若考虑所有分量则会导致训练时间急剧增加;若随机选取 IMF 分量,试验结果缺乏严谨性。自适应策略可有效地平衡收敛性和均匀性,获得更好的优化性能和鲁棒性^[31]。为此,本文提出基于自适应策略的 ICEEMD,通过皮尔逊相关系数 $\rho(\cdot)$ 自适应选取 CEEMD 分解后的 IMF 分量,即:

$$\rho[\mu_i, S(k)] = \frac{Cov[\mu_i, S(k)]}{\sqrt{var(\mu_i) \cdot var[S(k)]}} \quad (6)$$

式中: $Cov[\mu_i, S(k)]$ 为 μ_i 和 $S(k)$ 的协方差; $var(\mu_i)$ 、 $var[S(k)]$ 分别为 μ_i 、 $S(k)$ 的方差。

经过 ICEEMD 处理后的某故障电流信号时频变换图如图 4 所示。图 4 仅列举了 IMF1 信号图。

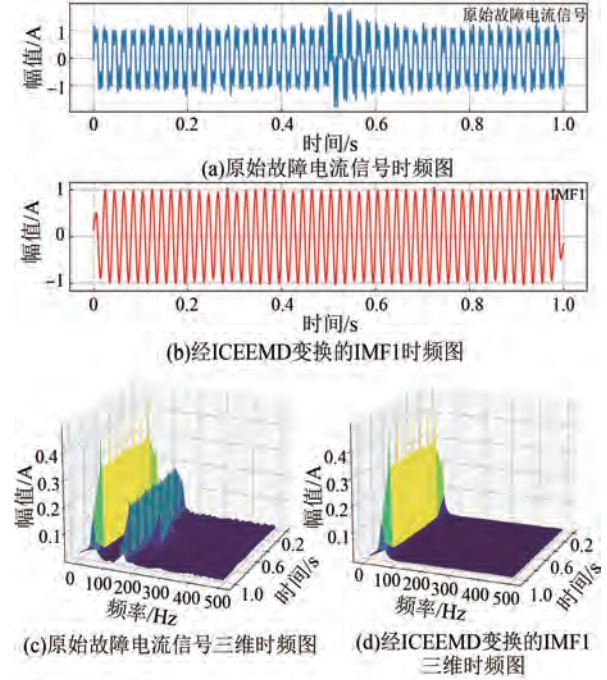


图 4 经过 ICEEMD 处理后的故障电流信号时频变换图

Fig. 4 Time frequency transformation diagrams of fault current signal processed by ICEEMD

由图 4 可知,ICEEMD 分解后得到的 IMF 分量具有较好的时频聚集特性,重构信号噪声水平较低,表现出良好的分解效果。

2.2 半监督故障检测模型

为提升模型的泛化能力和故障检测性能,本文基于协同训练理念设计了一种半监督学习模型框架,如图 5 所示。该框架通过持续迭代给无标签数据分配伪标签,并将伪标签作为真实标签重新加入训练集,从而扩展样本数据集。该框架结合 TCN 和 Transformer 两个互补的分类器网络进行协同训练。其中,TCN 模型擅长捕获序列数据的局部特征,可通过卷积有效捕捉局部异常模式,TCN 的并行计算特性使其在迭代训练时更高效,适合半监督学习的大规模数据场景;而 Transformer 模型更擅长全局建模,从全局视角出

发, 聚焦于序列数据的整体特征。

设第 i 个数据的输入特征为 x_i , 可得:

$$\begin{cases} p_i^c = f_{\eta}^c(x_i) \\ p_i^l = f_{\eta}^l(x_i) \end{cases} \quad (7)$$

式中: p_i^c 、 p_i^l 和 $f_{\eta}^c(\cdot)$ 、 $f_{\eta}^l(\cdot)$ 分别为 TCN 模型、Transformer 模型的预测结果和表达式。

基于式 (7) 的预测结果, 通过 TCN 和 Transformer 协同训练所生成的伪标签 ql_i^c 、 ql_i^l 为

$$\begin{cases} ql_i^c = \arg \max(p_i^c) \\ ql_i^l = \arg \max(p_i^l) \end{cases} \quad (8)$$

式中: $\arg \max(\cdot)$ 为预测结果中概率值最大对应的标签。

获取伪标签后, 采用交叉熵损失函数计算无标签数据的协同训练损失, 以此优化模型, 如式 (9) 所示:

$$L_{\text{ctl}} = L_{\text{ce}}(p_i^c, ql_i^c) + L_{\text{ce}}(p_i^l, ql_i^l) \quad (9)$$

式中: L_{ctl} 为协同训练无标签数据获得的总损失;

$L_{\text{ce}}(\cdot)$ 交叉熵损失函数。

有标签数据通过协同训练框架学习, 利用交叉熵损失函数得到 TCN 模型和 Transformer 模型的有监督总损失 L_{sup} :

$$L_{\text{sup}} = L_{\text{ce}}(p_i^c, y_i) + L_{\text{ce}}(p_i^l, y_i) \quad (10)$$

式中: y_i 为第 i 个输入数据对应的真实类别标签。

为进一步优化协同训练模型, 计算总训练损失 L_{total} 。本文采用动态加权系数 $\lambda(n)$ 调节协同 L_{ctl} 及 L_{sup} , 如式 (11) 所示:

$$\begin{cases} L_{\text{total}} = L_{\text{sup}} + \lambda(n) L_{\text{ctl}} \\ \lambda(n) = \lambda_{\text{max}} e^{-5 \left(1 - \frac{n_i}{n_{\text{total}}}\right)^2} \end{cases} \quad (11)$$

式中: n_i 为当前训练迭代次数; n_{total} 为训练所需总迭代次数; λ_{max} 为加权系数最大值。

λ_{max} 取值通常在 0.05~0.2 之间^[32], λ_{max} 过大易放大伪标签误差, 过小则会削弱无标签样本学习能力, 因此本文综合考虑选择 $\lambda_{\text{max}} = 0.1$ 。

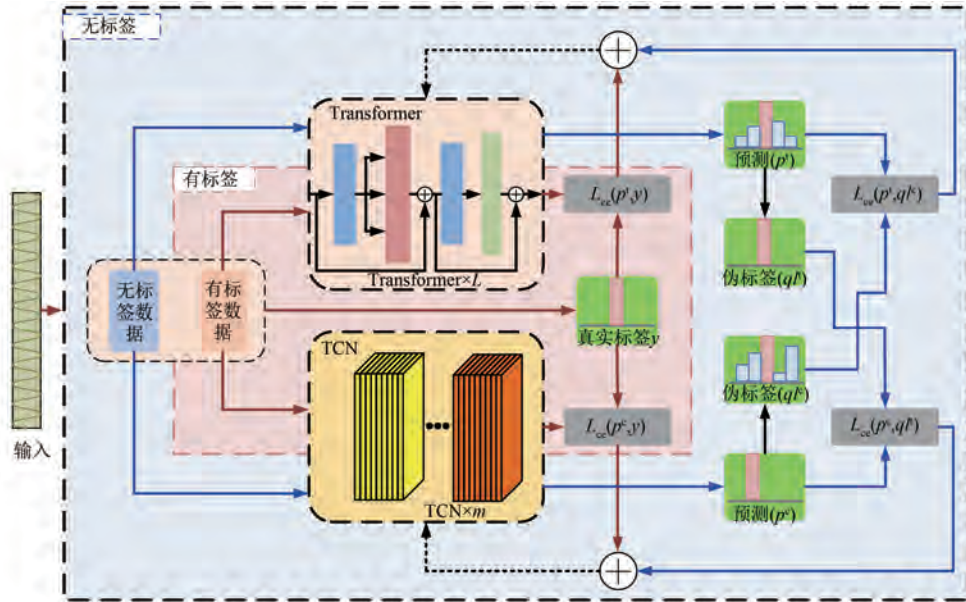


图 5 半监督学习模型框架

Fig. 5 Semi-supervised learning model framework

2.3 检测模型构建

2.3.1 Transformer 模型构建

Transformer 模型架构如图 6 所示。序列嵌入模块主要将输入数据嵌入到高维空间, 通过线性向量映射到所选定的编码维度, 同时通过添加位置编码将输入数据贴上唯一的位置标识符, 该模块使得模型能更全面地学习数据序列的中长距离

依赖关系。

特征提取模块由 L 层 Transformer 模块组成, 通过探究各编码段向量间的关联信息, 提取故障电流数据序列中的全局特征, 具体为

$$\begin{cases} \mathbf{I}' = f_{\text{LN}}[\mathbf{I} + f_{\text{multihead}}(\mathbf{I})] \\ f_{\text{block}}(\mathbf{I}) = f_{\text{LN}}[\mathbf{I}' + f_{\text{MLP}}(\mathbf{I}')] \end{cases} \quad (12)$$

式中: $f_{\text{LN}}(\cdot)$ 为正则化层操作; $f_{\text{block}}(\cdot)$ 为

Transform 模型的输出; $f_{\text{multihead}}(\cdot)$ 为多头注意力函数; I 为输入向量; $f_{\text{MLP}}(\cdot)$ 为多层感知机函数。

分类器由两个线性层组成,并采用 softmax 激活函数得到每种故障类型的概率输出,概率最大的类型即为模型预测的故障类型。

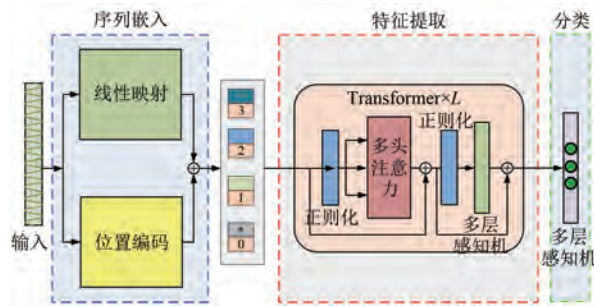


图 6 Transformer 模型架构

Fig. 6 Transformer model architecture

2.3.2 TCN 模型构建

TCN 模型由 Bai 等人提出^[33],是一种专门为序列建模和时间序列处理设计的卷积神经网络架构,如图 7 所示。TCN 模型结合了因果卷积和空洞卷积的特性,旨在高效捕捉时间序列中的长期依赖关系,同时避免传统循环神经网络的梯度消失或计算效率低的问题。




图 7 TCN 模型架构

Fig. 7 TCN model architecture

扩张因果卷积运算可表示为

$$F(\mathbf{x}_t) = (\mathbf{x} \times f)\mathbf{x}_t = \sum_{i=0}^{k-1} f_i \cdot \mathbf{x}_{(t-d) \cdot t} \quad (13)$$

式中: $\mathbf{x} \in \mathbf{R}^{T \times C}$, T 为序列长度, C 为特征维度; $F(\mathbf{x}_t)$ 为模型神经元输出; \mathbf{x}_t 为时间序列; f 为筛选器; k 为卷积核大小; d 为扩张因子。

为缓解深层网络的梯度消失问题,TCN 模型通常采用多个残差块连接,输入数据经扩张因果卷积层、归一化层、ReLU 激活函数及 Dropout 层

后,被送至下一残差块,每个残差块的输出通过堆叠逐步扩大感受野,最终覆盖整个序列。同时,将输入通过一维 3×3 卷积提取局部信息,并将提取的信息直接加到 3 个残差块后再经过多层全连接层输出。TCN 的并行计算特性使其在迭代训练时更高效,更适合半监督学习的大规模数据场景。

本文所用 TCN 模型参数如表 1 所示。该模型主要由 3 个残差块、3 层全连接层分类器构成。该结构均采用小卷积核组合,可极大减少网络中的参数,进而提高模型的泛化能力。

表 1 TCN 模型参数

Tab. 1 TCN model parameters

参数名称	参数值
卷积核大小	3×3
扩张因子	[1, 2, 4, 8]
卷积通道数	64
Dropout	0.2
学习率	$1e-5$
优化器	Adam

3 试验与分析

为验证本文提方法的有效性 with 精确性,所有试验均在一台配备 i7-8750HQ 处理器,16 GB 内存和 NVIDIA GeForce GTX 1060Ti 显卡的计算机上进行,使用 PyTorch 深度学习框架构建半监督弱特征故障检测模型。并基于 PSCAD 平台建立 10 kV 辐射型配电网模型,如图 8 所示。

图 8 所示的电力系统高压侧采用 220 kV 电压,通过单母线分段结构连接两台 220 kV/10 kV 的变压器,从而构建 10 kV 交流配电系统。在母线 5 与母线 10 处配置电容器进行无功功率补偿,以维持线路末端压降不超过 3% 的标准。该配电系统有 2 条 10 kV 出线、14 个负荷节点,并通过控制开关 S 调整系统中性点接地方式。设置采样频率为 20 kHz;故障类型为单相低阻接地和单相高阻接地(均为 A 相故障,分别在 15%、55% 和 90% 处各设置 3 组不同的故障参数值);故障点 16 处,每隔 15° 设置 1 个不同的故障初相角(5° 、 20° 、 35° 、 50° 、 65° 、 80° 、 95° 、 110° 、 125° 、 140° 、 155° 和 170°)。通过多维参数配置构建零序电流样本集,其中包含 1 152 组故障工况数据。为真实反映电




图 8 10 kV 配电网拓扑结构示意图

Fig. 8 Schematic diagram of the 10 kV distribution network topology

网运行特性,同步采集了 4 608 组正常工况下的零序电流样本,共形成原始数据集 1 152+4 608 = 5 760 组。为确保模型训练的有效性与评估可靠性,将原始数据集按 6:2:2 的比例分为训练集、验证集和测试集。

3.1 评价指标构建

将故障按真实标签与预测标签分为真阳性 (True Positive, TP)、假阳性 (False Positive, FP)、真阴性 (True Negative, TN) 与假阴性 (False Negative, FN) 四种类别。故障检测本质上是分类任务,用表 2 所示的混淆矩阵的分类结果与实际值进行比较,从而直观地表示各类别的分类状态。

表 2 故障检测中的混淆矩阵

Tab. 2 Confusion matrix in fault detection		
类别	预测为正类别	预测为负类别
实际为正类别	TP	FN
实际为负类别	FP	TN

构建评价指标,包括准确率 (Accuracy, ACC) 和 F1 分数 (F1-Score, F1), 如式 (14)、式 (15) 所示:

ACC = (TP + TN) / (TP + TN + FP + FN) (14)

F1 = 2[TP / (TP + FP)] · Recall / [TP / (TP + FP)] + Recall (15)

式中:Recall 为召回率。

此外,受试者工作特征 (Receiver Operating Characteristic, ROC) 曲线描述了真阳性率 (True Positive Rate, TPR) 和假阳性率 (False Positive Rate, FPR) 变化时的相对关系,适合在数据集不平衡时评估分类器的整体性能,ROC 曲线下面积 (Area Under the Curve, AUC) 越大,模型性能越好。

3.2 故障电流信号处理

采用 ICEEMD 对故障零序电流信号进行特征提取,获得 IMF1~IMF5 五个 IMF 分量,结果如图 9 所示。对于配电网故障检测,一般采用 IMF1 和 IMF2 作为检测用尺度^[34]。IMF1 分量保留了原始信号的绝大部分分量,IMF2~IMF5 受谐波分量影响,并不能体现原始故障信号的主要特征。因此,本文选择 IMF1 作为检测用尺度。




图 9 ICEEMD 信号处理结果

Fig. 9 ICEEMD signal processing results

3.3 模型超参数分析

在 TCN 和 Transformer 组成的半监督模型中,TCN 卷积核大小 k 、扩张因子 d 和 Transformer 个数 L 、多头注意力头数 h 共同影响半监督模型的复杂度和检测精度。半监督模型中各超参数值越大,模型检测性能越强,但模型复杂度也快速提升,存在过拟合风险。为平衡模型复杂度和检测效果,应选择合适的模型超参数。本文半监督模型超参数设置范围及最优值如表 3 所示。

采用最佳配置的超参数对半监督模型进行迭代训练,图 10 展示了该模型在不同训练周期下的

ACC 与损失函数演变过程。学习曲线显示以下特征:(1)收敛轨迹平滑无明显振荡,表明学习过程稳定可控;(2)训练集与验证集的 ACC 及损失值同步收敛,其偏差范围始终低于预设阈值。这些特征表明模型在参数空间探索中实现了理想的泛化能力平衡,有效规避了欠拟合与过拟合的潜在问题。

表 3 半监督模型超参数设置
Tab.3 Hyperparameter setting for semi-supervised model

超参数名称	设置范围	最优值
L	2、3、4、5、6	6
h	4、6、8、16	8
d	[1,2,4]、[1,2,4,8]、[1,2,3,6]	[1,2,4,8]
k	3×3、5×5、7×7	3×3




图 10 不同训练周期的 ACC 与模型损失
Fig. 10 ACC and model loss for different training epochs

3.4 半监督模型试验与分析

为评估半监督模型的性能,本文采用 15%、25%、35%、45%、65% 和 85% 的有标签数据,其余部分作为无标签数据,并通过测试集检验不同标签比例下的检测效果。为建立性能基准,同步实施全监督对照试验(标注率 100%)。半监督模型(1[#])与全监督模型(2[#])在不同标签数据比例下的性能指标如表 4 所示。

由表 4 可知,随着有标签数据比例的增加,全监督模型的各项性能指标持续提升,其中 AUC 从 90.13% 上升到 99.12%,FPR 从 9.67% 下降至 1.14%,表明标签数据量的增多显著增强了有监督学习的整体性能。对于半监督模型,当有标签数据比例从 15% 增至 45% 时,性能指标逐步改

善,AUC 从 96.04% 提升至 98.97%,FPR 从 5.66% 降至 1.38%;但当有标签数据比例进一步提高至 65% 及以上时,各项指标仍有小幅提升,但增幅明显减小,呈现出性能提升逐渐趋缓的趋势。这表明,当有标签数据占比达到 45% 时,基于 TCN 与 Transformer 网络协同训练的半监督学习模型已有效挖掘了无标签数据分布特征蕴含的信息,此时模型的检测性能已接近全监督学习模型的水平。

表 4 不同标签数据比例下两种模型性能指标对比
Tab.4 Comparison of performance indicators for two models under different labelled data ratios

比例/%	模型	性能指标/%				
		AUC	ACC	FPR	TPR	F1
15	1 [#]	96.04	91.13	5.66	91.56	80.25
	2 [#]	90.13	87.58	9.67	89.63	80.17
25	1 [#]	97.03	92.09	3.11	91.61	84.46
	2 [#]	91.02	88.32	8.63	89.99	82.68
35	1 [#]	98.21	93.63	2.86	90.13	85.67
	2 [#]	92.28	90.26	6.46	90.01	84.33
45	1 [#]	98.97	95.53	1.38	89.93	88.04
	2 [#]	94.37	91.22	5.51	89.56	85.87
65	1 [#]	99.23	96.07	1.27	89.78	89.01
	2 [#]	96.25	93.22	3.35	90.09	88.48
85	1 [#]	99.23	96.15	1.22	90.21	90.03
	2 [#]	99.12	96.13	1.14	90.11	90.15

当有标签数据比例超过 65% 时,半监督模型的性能提升幅度逐渐减小,并在 85% 附近与全监督模型表现趋于接近。而当有标签数据比例低于 65% 时,半监督模型展现出较大优势,尤其在标签数据少于 25% 时优势尤为突出。例如,当标签数据比例为 15% 时,半监督模型的 AUC 达到 96.04%,比全监督模型高 5.91%,而 FPR 仅为 5.66%,远低于全监督模型的 9.67%。

综上所述,本文所提半监督模型具备优异的检测性能和泛化能力,特别是在有标签数据较少的情况下,其优势尤为显著。图 11 展示了两模型在不同标签数据比例下的 AUC 与 FPR 对比结果。

为验证所提半监督模型在检测单相低阻接地和单相高阻接地故障时的有效性,在有标签数据占比为 40% 的情况下,使用图 12 所示的混淆矩阵来可视化其验证效果。图 12 中,标签“0”为正常




图 11 不同标签数据比例下两种模型的 AUC 和 FPR

Fig. 11 AUC and FPR of the two models under different labelled data proportions

状态;标签“1”为单相低阻接地故障;标签“2”为单相高阻接地故障。

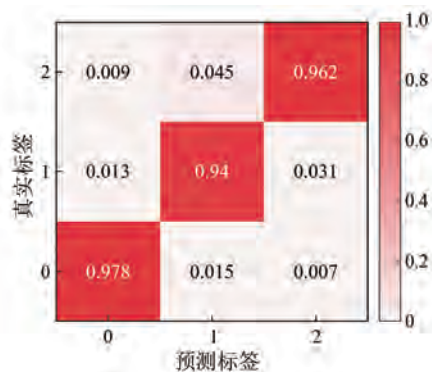


图 12 两种故障检测混淆矩阵

Fig. 12 Confusion matrix of two kinds of fault detection

由图 12 可知,半监督模型对正常状态、单相低阻接地故障和单相高阻接地故障的识别准确率分别达到 97.8%、94% 和 96.2%,均表现出较高的精度。

3.5 与现有方法的比较与分析

本文使用 Adam 优化器更新模型权重,以最小化损失函数。图 13(a)展示了随训练周期增加,有标签数据损失和无标签数据损失的变化情况。可见,无标签数据损失和有标签数据损失均随着训练周期的增加逐渐下降并趋于稳定,最终达到收敛。

图 13(b)展示了动态加权系数 $\lambda(n)$ 对协同训练中无标签数据损失权重的调节过程。随着训练周期的增多, λ 从 0 逐步增加至 0.1,半监督模型初期主要聚焦于有标签数据的训练,随后逐渐加强对无标签数据的学习。这种训练策略有效避

免了因学习无标签数据的错误伪标签而导致训练过程剧烈波动或模型无法收敛的问题。通过一定周期的有标签数据训练,可大幅降低无标签数据被错误标记为伪标签的风险,从而更好地挖掘无标签数据的分布特征信息,提升模型的泛化能力和检测性能。

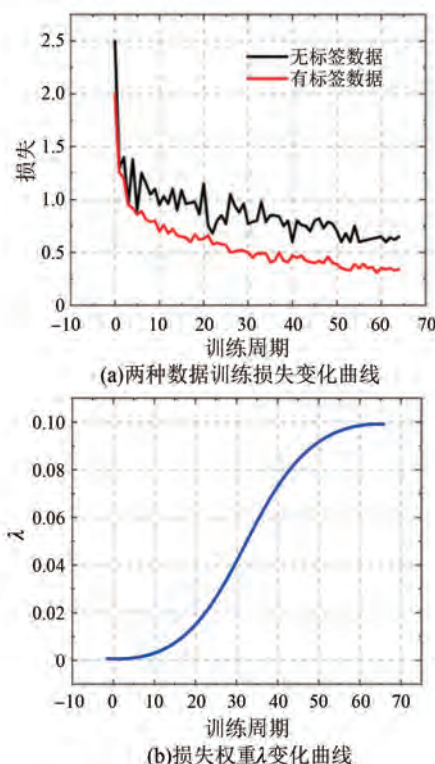


图 13 半监督模型损失变化曲线

Fig. 13 Loss change curve of semi-supervised model

半监督模型中 Transformer 模型与 TCN 模型的训练集和验证集 ACC 变化曲线如图 14 所示。

由图 14 可知,训练集上 Transformer 模型和 TCN 模型的 ACC 随训练周期的增加逐步稳定,且均超过 90%;验证集上两模型的 ACC 的变化趋势与训练集相似,但曲线波动幅度更大,这是因为验证集上的无标签数据被错误标记,导致梯度更新方向偏误,ACC 曲线波动较大,但随着协同训练的正反馈机制逐步发挥作用,波动逐渐减小,最终曲线趋于收敛。可见,在协同训练框架下,两模型通过相互正反馈,为无标签数据分配正确标签,并引导对方模型的训练,从而提升整体性能。

为了评估所提 TransTCN 协同训练半监督模型的有效性,通过消融试验进行验证。在 15% 有标签数据比例下,TransTCN 半监督学习模型、




图 14 训练集和验证集 ACC 变化曲线

Fig. 14 ACC change curves of training set and validation set

Transformer 半监督学习模型以及 TCN 半监督学习模型的检测性能对比如表 5 所示。

表 5 不同模型的检测性能对比

Tab. 5 Comparison of detection performance across different models

模型名称	性能指标/%				
	AUC	ACC	FPR	TPR	F1
TransTCN	96.04	91.13	5.66	91.56	80.25
Transformer	95.02	88.34	6.51	82.32	77.85
TCN	91.82	86.34	9.76	80.22	71.63

由表 5 可知,TransTCN 半监督模型在各项指标上均优于 Transformer 和 TCN 半监督模型,性能整体提升约 1%~10%,FPR 降低约 1%~5%。同时,Transformer 半监督模型的表现优于 TCN 半监督模型,可见 Transformer 模型在故障检测任务中更具适用性。

为了更深入地评估 TransTCN 半监督模型的性能,将其与图方法 (Graph-based Method, GM)^[35]、变分自编码器 (Variational Autoencoder, VAE)^[36]、半监督支持向量机 (Semi-supervised

SVM, S3VM)^[37]、半监督生成对抗网络 (Semi-supervised Generative Adversarial Network, SGAN)^[38] 和一致性正则化 (Consistency Regularization, CR)^[39] 等五种现有半监督算法进行对比分析。各算法主要参数设置如表 6 所示。

表 6 各算法主要参数设置

Tab. 6 Main parameters setting of each algorithm

算法名称	参数设置
GM	k 近邻数为 10,传播系数为 0.8,学习率为 0.001
VAE	隐变量维度为 10,学习率为 0.000 1,KL 散度权重为 1
S3VM	惩罚参数为 0.1,核函数为径向基函数,最大迭代次数为 100
SGAN	学习率为 0.000 1,平衡系数为 0.1,优化器为 Adam
CR	置信度阈值为 0.95,一致性损失权重为 1.0

在 15% 有标签数据比例下,不同算法的检测性能指标对比如表 7 所示。可见,本文所提 TransTCN 模型的检测性能指标均优于其他算法。其余四种算法的整体性能排名为:CR>SGAN>S3VM>VAE>GM。

表 7 不同算法的检测性能指标对比

Tab. 7 Detection performance indicators by different algorithms

算法名称	性能指标/100%			
	ACC	TPR	FPR	F1
GM	86.32	76.53	8.56	70.79
VAE	87.69	77.86	9.67	73.13
S3VM	89.21	78.34	8.42	74.68
SGAN	88.67	83.91	7.23	77.72
CR	90.68	89.56	6.33	87.31
TransTCN	95.31	97.33	5.12	90.13

为全面评估及量化所提 TransTCN 半监督模型检测方法的性能,设置训练集、测试集及验证集比例为 6:2:2,采用 ROC 曲线的 AUC 对 CR、SGAN、S3VM、VAE、GM 与 TransTCN 模型的检测性能进行量化,结果如图 15 所示。

理想的 ROC 曲线应尽量贴近左上角,表明检测性能更优。由图 15 可知,本文所提 TransTCN 半监督模型的 ROC 曲线更接近左上角,其 AUC 最高,检测效果优于其他方法。

3.6 灵敏度分析

为了全面验证 TransTCN 半监督模型在不同




图 15 各算法的 ROC 曲线

Fig. 15 ROC curves for each algorithm

数据规模下的性能稳定性、鲁棒性和泛化能力,以数据集大小作为关键参数,通过灵敏度分析来评估模型的稳定性。分别选取数据集的 5%、15%、25%、35%、45%、55%、65%、75%、85%、95% 及 100% 作为试验参数,对模型进行十次重复训练,并以性能均值和标准差作为最终结果。试验结果如图 16 所示,采用 FPR 和 TPR 两个指标来评估模型在不同数据集比例下的表现。




图 16 数据集比例对模型性能影响

Fig. 16 Impact of dataset proportions on model performance

由图 16 可知,当数据集比例低于 65% 时,随数据集比例的升高,FPR 逐渐降低,TPR 逐渐升高,伴随轻微波动;当比例高于 65% 时,FPR 和 TPR 趋于稳定,不随数据比例增加而显著变化。结果表明,在数据量较小时,模型的分类精度随样本量增加而不断提高;当数据量达到一定规模后,分类精度维持在较高水平且保持稳定。可见 TransTCN 半监督模型对数据的依赖性较低,特别适合数据获取困难、成本较高的故障检测应用场景。

4 结语

本文构建了一种结合 Transformer 全局建模能力与 TCN 局部特征提取优势的 TransTCN 半监督协同训练模型,用于配电网弱特征故障检测。其核心策略是利用少量有标签样本引导模型学习,从而为大量无标签数据生成高质量的伪标签进行扩充训练,并通过设计加权损失函数实现模型参数的迭代优化与性能提升。采用 ICEEMD 对 PSCAD 平台生成的 10 kV 辐射型配电网故障信号进行预处理后,在 15% 有标签数据比例下,模型对弱特征故障的识别准确率达 95.31%。性能评估结果表明,TransTCN 半监督模型具有强大的局部和全局特征提取能力,泛化能力优异,显著降低了过拟合风险。其检测精度、鲁棒性及泛化能力均超越现有半监督深度学习方法。所提 TransTCN 半监督模型为智能电网弱特征故障的早期精准检测提供了高效解决方案,为提升电网运行可靠性和用户用电质量提供了关键技术支撑。

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

邱桂华进行了方案设计、内容总结与论文撰写,郭志臻进行了试验研究,邵玉明和刘剑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 summary and paper writing were carried out by Qiu Guihua. The experimental study was conducted by Guo Zhishen. The manuscript was reviewed and revised by Shao Yuming and Liu Jian. All authors have read and approved the final version of the manuscript for submission.

参考文献

- [1] 舒印彪, 赵勇, 赵良, 等. “双碳”目标下我国能源电力低碳转型路径[J]. 中国电机工程学报,

- 2023, 43(5): 1663-1671.
- Shu Y B, Zhao Y, Zhao L, et al. Study on low carbon energy transition path toward carbon peak and carbon neutrality [J]. Proceedings of the CSEE, 2023, 43(5): 1663-1671.
- [2] 马钊, 张恒旭, 赵浩然, 等. 双碳目标下配用电系统的新使命和新挑战[J]. 中国电机工程报, 2022, 42(19): 6931-6945.
- Ma Z, Zhang H X, Zhao H R, et al. New mission and challenge of power distribution and consumption system under dual-carbon target [J]. Proceedings of the CSEE, 2022, 42(19): 6931-6945.
- [3] 周孝信, 赵强, 张玉琼, 等. “双碳”目标下我国能源电力系统发展趋势分析: 绿电替代与绿氢替代[J]. 中国电机工程学报, 2024, 44(17): 6707-6721.
- Zhou X X, Zhao Q, Zhang Y Q, et al. Analysis of the development trend of China's energy and power system under the dual carbon target: Green electricity substitution and green hydrogen substitution [J]. Proceedings of the CSEE, 2024, 44(17): 6707-6721.
- [4] 周珊, 张伟杰, 许丹宁, 等. 基于模糊二阶高通滤波的光伏混合储能直流微网的功率分配控制[J]. 电机与控制应用, 2025, 52(1): 52-63.
- Zhou S, Zhang W J, Xu D N, et al. Power allocation control of photovoltaic hybrid energy storage DC microgrid based on fuzzy second-order high-pass filtering [J]. Electric Machines & Control Application, 2025, 52(1): 52-63.
- [5] 李伟军, 李天友, 苏俊. 基于随机森林的光伏直流侧串联电弧故障检测方法[J]. 供用电, 2025, 42(2): 108-115.
- Li W J, Li T Y, Su J. Series arc fault detection method for photovoltaic DC side based on random forest [J]. Distribution & Utilization, 2025, 42(2): 108-115.
- [6] 豆敏娜, 田影, 王毅钊, 等. 基于积分面积的直流配电网单极接地故障选线方法[J]. 电网与清洁能源, 2025, 41(1): 10-16.
- Dou M N, Tian Y, Wang Y Z, et al. A single-pole ground fault selection method for DC distribution networks based on integral area [J]. Power System and Clean Energy, 2025, 41(1): 10-16.
- [7] 温伟杰, 胡铁伟, 陈晓龙, 等. 典型配电故障下直流偏置电压形成及电压互感器熔断分析[J]. 电工技术学报, 2025, 40(1): 226-240.
- Wen W J, Hu T W, Chen X L, et al. Analysis of DC bias voltage formation and voltage transformer melting under typical distribution faults [J]. Transactions on China Electrotechnical Society, 2025, 40(1): 226-240.
- [8] Pompodakis E E, Kryonidis G C, Demoulias C, et al. A generic power flow algorithm for unbalanced islanded hybrid AC/DC microgrids [J]. IEEE Transactions on Power Systems, 2021, 36(2): 1107-1120.
- [9] 韦延方, 杨萍, 杨湛晔, 等. 基于 EWT 改进限流电抗电压的柔性直流配电网故障保护方法[J]. 电力系统保护与控制, 2024, 52(23): 22-32.
- Wei Y F, Yang P, Yang Z Y, et al. An improved fault protection method for a flexible DC distribution network based on EWT current limiting reactance voltage [J]. Power System Protection and Control, 2024, 52(23): 22-32.
- [10] Yadav N, Tumuru N R. Filter capacitor current dynamics-based frequency-domain fault detection approach for grid-connected low-voltage DC microgrid [J]. IEEE Transactions on Industrial Electronics, 2023, 70(12): 12784-12794.
- [11] Zhang Y, Chung C Y, Wen F, et al. An analytic model for fault diagnosis in power systems utilizing redundancy and temporal information of alarm messages [J]. IEEE Transactions on Power Systems, 2016, 31(6): 4877-4886.
- [12] Jiang H G, Dai X X, Gao D W Z, et al. Spatial-temporal synchrophasor data characterization and analytics in smart grid fault detection, identification, and impact causal analysis [J]. IEEE Transactions on Smart Grid, 2016, 7(5): 2525-2536.
- [13] 丁剑, 白晓民, 赵伟, 等. 基于复杂事件处理技术的电网故障信息分析及诊断方法[J]. 中国电机工程学报, 2007, 27(28): 40-45.
- Ding J, Bai X M, Zhao W, et al. Fault information analysis and diagnosis method of power system based on complex event processing technology [J]. Proceedings of the CSEE, 2007, 27(28): 40-45.
- [14] 刘洋, 赵艳雷, Nirmal Nair, 等. 基于同步量测全尺度能量的配电网高阻故障动态检测方法[J]. 电网技术, 2020, 44(8): 3073-3080.
- Liu Y, Zhao Y L, Nirmal N, et al. High impedance fault detection method based on the synchronous

- dynamic full-scale energy for the distribution network [J]. *Power System Technology*, 2020, 44(8): 3073-3080.
- [15] 郑星炯. 基于支持向量机的配电线路高阻接地故障检测方法[J]. *电子设计工程*, 2015, 23(14): 122-125.
- Zheng X J. SVM-based method of high impedance fault detection in distribution network [J]. *Electronic Design Engineering*, 2015, 23(14): 122-125.
- [16] Peng N, Ye K, Liang R, et al. Single-phase-to-earth faulty feeder detection in power distribution network based on amplitude ratio of zero-mode transients [J]. *IEEE Access*, 2019, 7: 117678-1176910.
- [17] 王时胜, 吴丽娜, 郭格. 基于 EMD 分解及相关分析法的配电网高阻接地故障定位[J]. *南昌大学学报(工科版)*, 2015, 37(2): 180-184.
- Wang S S, Wu L N, Guo G. High-impedance-grounding fault location for distribution network based on empirical mode decomposition method and correlation analysis [J]. *Journal of Nanchang University (Engineering & Technology)*, 2015, 37(2): 180-184.
- [18] Santos W C, Lopes F V, Brito N S D, et al. High-impedance fault identification on distribution networks [J]. *IEEE Transactions on Power Delivery*, 2017, 32(1): 23-32.
- [19] 韦延方, 王志杰, 王鹏, 等. 基于 VMD 模糊熵与 GG 聚类的直流配电网故障检测方法[J]. *电机与控制学报*, 2024, 28(2): 129-141.
- Wei Y F, Wang Z J, Wang P, et al. Fault detection method for DC distribution network based on VMD fuzzy entropy and GG clustering [J]. *Electric Machines and Control*, 2024, 28(2): 129-141.
- [20] 白浩, 李鹏, 袁智勇, 等. 人工智能在配电网高阻接地故障检测中的应用及展望[J]. *南方电网技术*, 2019, 13(2): 34-44.
- Bai H, Li P, Yuan Z Y, et al. Application and prospect of artificial intelligence in high impedance fault detection of distribution network [J]. *Southern Power System Technology*, 2019, 13(2): 34-44.
- [21] Wei H B, Wei H, Lyu Z L, et al. Deep belief network based faulty feeder detection of single-phase ground fault [J]. *IEEE Access*, 2021, 9: 158961-158971.
- [22] Shrinivas G M, Saravanan A, Pradeep G V, et al. Fault identification & classification in an interconnected power system network using machine learning [C]//2021 IEEE 5th International Conference on Condition Assessment Techniques in Electrical Systems, Kozhikode, 2021.
- [23] 高伟, 陈伟凡, 杨耿杰, 等. 基于奇异值分解和多级支持向量机的配电网故障类型识别[J]. *电子测量与仪器学报*, 2018, 32(2): 62-71.
- Gao W, Chen W F, Yang G J, et al. Fault type identification for distribution network based on singular value decomposition and multi-level support vector machine [J]. *Journal of Electronic Measurement and Instrumentation*, 2018, 32(2): 62-71.
- [24] 张晓鹏, 白洁, 孙乃君, 等. 基于特征融合的 GA-SVM 配电网单相接地故障选线方法[J]. *电测与仪表*, 2025, 62(1): 140-148.
- Zhang X P, Bai J, Sun N J, et al. GA-SVM method for single-phase grounding fault line selection in distribution network based on feature fusion [J]. *Electrical Measurement & Instrumentation*, 2025, 62(1): 140-148.
- [25] 翁月莹, 陈翔宇, 肖新华, 等. 基于 PSO 和贝叶斯分类器的配电网高阻接地故障识别技术[J]. *电测与仪表*, 2020, 57(2): 52-56.
- Weng Y Y, Chen X Y, Xiao X H, et al. High impedance ground fault identification technology based on PSO and Bayes classifier [J]. *Electrical Measurement & Instrumentation*, 2020, 57(2): 52-56.
- [26] 李临凤, 饶丹, 樊瑞, 等. 基于双向 LSTM 和注意力机制的输电线路故障判别方法[J]. *广东电力*, 2022, 35(11): 91-98.
- Li L F, Rao D, Fan R, et al. Fault discrimination method based on bi-LSTM-attention for transmission lines [J]. *Guangdong Electric Power*, 2022, 35(11): 91-98.
- [27] 崔朴奕, 李国丽, 张倩, 等. 基于 VMD-CNN 的小电流接地系统故障电弧检测方法研究[J]. *电力系统保护与控制*, 2021, 49(23): 18-25.
- Cui P Y, Li G L, Zhang Q, et al. A fault arc detection method of a small current grounding system based on VMD-CNN [J]. *Power System Protection and Control*, 2021, 49(23): 18-25.
- [28] Zhang Y J, Wang X J, He J H, et al. A transfer learning-based high impedance fault detection method under a cloud-edge collaboration framework [J].

- IEEE Access, 2020, 8: 165099-165110.
- [29] Ali J B, Fnaiech N, Saidi L, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals [J]. Applied Acoustics, 2015, 89: 16-27.
- [30] Zhao H M, Sun M, Deng W, et al. A new feature extraction method based on EEMD and multi-scale fuzzy entropy for motor bearing [J]. Entropy, 2016, 19(1): 14.
- [31] Benesty J, Chen J D, Huang Y T. On the importance of the Pearson correlation coefficient in noise reduction [J]. IEEE Transactions on Audio, Speech, and Language Processing, 2008, 16(4): 757-765.
- [32] Mei C Y, Yang X G, Zhou M, et al. Semi-supervised image segmentation using a residual-driven mean teacher and an exponential Dice loss [J]. Artificial Intelligence in Medicine, 2024, 148: 102757.
- [33] Bai S J, Kolter J Z, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [J]. arXiv, 2018: 1803.01271.
- [34] 张大波, 李雪婷, 陶维青. 基于边缘计算和深度学习的有限信息配电网单相接地故障区段定位 [J]. 电力系统保护与控制, 2023, 51(24): 22-32.
- Zhang D B, Li X T, Tao W Q. Single-phase ground fault section location in distribution networks with limited information based on edge computing and deep learning [J]. Power System Protection and Control, 2023, 51(24): 22-32.
- [35] Ma J L, Wang X L, Xiao B. An image segmentation method based on simple linear iterative clustering and graph-based semi-supervised learning [C]//2015 International Conference on Orange Technologies, Hong Kong, 2015.
- [36] Bond-taylor S, Leach A, Long Y, et al. Deep generative modelling: A comparative review of VAEs, GANs, normalizing flows, energy-based and autoregressive models [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 44(11): 7327-7347.
- [37] Pan D W, Nie L Q, Kang W X, et al. UAV anomaly detection using active learning and improved S3VM model [C]//2020 International Conference on Sensing, Measurement & Data Analytics in the era of Artificial Intelligence, Xi'an, 2020.
- [38] Shim S, Kim J, Lee S W, et al. Road damage detection using super-resolution and semi-supervised learning with generative adversarial network [J]. Automation in Construction, 2022, 135: 104139.
- [39] Ma Y, Shi H B, Tan S, et al. Consistency regularization auto-encoder network for semi-supervised process fault diagnosis [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 3517215.

收稿日期:2025-08-27

收到修改稿日期:2025-10-15

作者简介:

邱桂华(1987—),男,博士,正高级工程师,研究方向为人工智能在电力系统中的应用、配电网调度运行, zhokuisf@126.com;

*通信作者:邱桂华(1987—),男,博士,正高级工程师,研究方向为人工智能在电力系统中的应用、配电网调度运行, zhokuisf@126.com。