

DOI: 10.19783/j.cnki.pspc.250522

# 基于优化模态分解与时空图卷积网络的光伏配电网 高阻抗故障诊断与定位方法研究

李彬<sup>1</sup>, 傅哲<sup>2</sup>, 肖羽<sup>2</sup>, 张琦<sup>2</sup>, 张湘毅<sup>2</sup>, 张毅<sup>2</sup>, 罗中戈<sup>2</sup>, 孙玉树<sup>3</sup>

(1. 国网北京大兴供电公司, 北京 102600; 2. 国网北京城区供电公司, 北京 100034; 3. 中国科学院电工研究所, 北京 100190)

**摘要:** 高比例光伏接入使配电网暂态特性复杂化, 导致传统方法在高阻抗故障诊断与定位时存在特征提取不充分、拓扑关联性不强的问题, 进而影响准确性。鉴于此, 提出一种基于斑马优化(zebra optimization algorithm, ZOA)多元变分模态分解(multivariate variational mode decomposition, MVMD)结合 Teager-Kaiser 能量算子(teager-kaiser energy operator, TKEO)多特征融合-时空图卷积神经网络(spatio-temporal graph convolutional network, STGCN)的光伏配电网高阻抗故障诊断与定位方法。首先利用 MVMD 处理多变量信号, 以有效融合多维数据并充分挖掘故障特征, 此外采用 ZOA 对 MVMD 参数优化, 进一步提升特征提取效果。其次通过 TKEO 增强 MVMD 最高频本征模态分量, 捕捉瞬时能量变化。最后构建多特征融合向量输入 STGCN, 通过长短期记忆层提取时序动态特征, 结合图卷积神经网络挖掘节点间空间拓扑关系, 实现时空特征联合建模。在 IEEE33 节点系统上进行了仿真测试, 结果表明相较于传统方法, 所提方法在光伏配电网高阻抗故障诊断与定位方面具有更高精度。

**关键词:** 配电网; 高阻抗; 故障诊断与定位; 斑马优化多元变分模态分解; 时空图卷积神经网络

## Research on high-impedance fault diagnosis and location in photovoltaic distribution networks based on optimized modal decomposition and spatiotemporal graph convolutional networks

LI Bin<sup>1</sup>, FU Zhe<sup>2</sup>, XIAO Yu<sup>2</sup>, ZHANG Qi<sup>2</sup>, ZHANG Xiangyi<sup>2</sup>, ZHANG Yi<sup>2</sup>, LUO Zhongge<sup>2</sup>, SUN Yushu<sup>3</sup>

(1. State Grid Beijing Daxing Electric Power Supply Company, Beijing 102600, China; 2. State Grid Beijing Urban District Power Supply Company, Beijing 100034, China; 3. Institute of Electrical Engineering, Chinese Academy of Sciences, Beijing 100190, China)

**Abstract:** The high penetration of photovoltaic (PV) generation complicates the transient characteristics of distribution networks, leading to insufficient feature extraction and weak topological correlation in traditional high-impedance fault (HIF) diagnosis and location methods, thereby degrading accuracy. To address these challenges, a novel HIF diagnosis and location method for PV-integrated distribution networks is proposed based on multi-feature fusion via zebra optimization algorithm (ZOA)-optimized multivariate variational mode decomposition (MVMD), combined with Teager-Kaiser energy operator (TKEO), and a spatiotemporal graph convolutional network (STGCN). First, MVMD processes multivariate signals to effectively fuse multi-dimensional data and fully extract fault features. Meanwhile, ZOA is used to optimize the MVMD parameters, further enhancing feature extraction performance. Second, TKEO is utilized to enhance the highest-frequency intrinsic mode function decomposed by MVMD, enabling the capture of transient energy variations. Finally, a multi-feature fusion vector set is constructed and fed into the STGCN, which employs long short-term memory layers to extract temporal dynamic features and integrates graph convolutional networks to explore spatial topological relationships among nodes, achieving joint spatiotemporal feature modeling. Simulation tests conducted on the IEEE 33-node system demonstrate that, compared to traditional methods, the proposed approach achieves higher accuracy in HIF diagnosis and location for PV distribution networks.

This work is supported by the National Science and Technology Major Project of China (No. 2025ZD0805200).

**Key words:** distribution network; high impedance; fault diagnosis and location; zebra optimization algorithm-optimized multivariate variational mode decomposition; spatiotemporal graph convolutional network

**基金项目:** 智能电网重大专项 (2030) (2025ZD0805200); 中国科学院青年创新促进会项目资助 (2023000018); 国网北京市电力公司科技项目资助 (520202230006)

## 0 引言

配电网作为电力系统的重要组成部分，直接与用户相连，其安全稳定运行对保障电力供应和用户用电质量至关重要。配电网线路由于线缆混合、分支线路多、运行环境复杂等因素，极易发生故障<sup>[1-3]</sup>。据统计在配电网故障中高阻抗故障占比较大，且因其故障电流小、特征不明显、检测难度大，难以完成故障诊断与定位<sup>[4-6]</sup>。同时光伏发电系统的接入使得配电网中谐波和噪声增加干扰故障检测，导致传统方法难以有效诊断<sup>[7-11]</sup>。准确快速地实现高阻抗故障诊断与定位，不仅能防止安全事故发生，保障供电的可靠性，还能减少电能损耗，降低经济损失。因此，开展光伏配电网高阻抗故障诊断与定位方法研究具有重要意义。

目前配电网故障诊断与定位方法可以分为基于模型与基于数据两类。在高阻抗故障检测中，基于模型的方法物理意义明确，并且对于系统动态场景已知的情况故障诊断准确率较高<sup>[12-14]</sup>。文献[15]通过建立谐振配电系统的等效电路，提出了一种在线计算核心系统参数的方法，从而实现高阻抗故障的检测与定位。文献[16]构建了工频模型，利用实际物理参数对单相接地故障零序电流进行模拟，提高了单相接地高阻抗故障分析的预测准确性和适用性。但是随着新能源并网，配电网的波动性和不确定性增大，使得基于模型的方法难以建立精确的数学模型，影响其故障诊断准确性。

基于数据的方法通过数据驱动的方式学习故障的特征，更适用于处理复杂故障，而特征提取对于提升故障诊断与定位的性能十分重要，尤其关于光伏配电网高阻抗故障这类微弱、非平稳信号的诊断与定位。文献[17]采用改进噪声自适应的经验模态分解(empirical mode decomposition, EMD)方法实现有源配电网高阻抗故障检测。文献[18]提出了一种基于离散小波分解和 Hilbert-Huang 变换的故障特征提取策略，表征高阻抗故障中的弱故障特征，以提高故障识别精度。为了减少分布式能源对故障检测的干扰，文献[19]采用变分模态分解(variational mode decomposition, VMD)得到的第一个分量，捕捉零序电压和零序电流的整体趋势特征，实现分布式发电系统(distributed generation, DG)配电网单线接地故障馈线检测。文献[20]基于 EMD 构建滤波器，建立零序电流的高维特征数据集，并采用主成分分析与 Hilbert 映射算法进行降维，实现故障识别并准确估计故障发生时间。尽管上述方法能够有效提取故障特征，但传统基于 EMD 或 VMD 的特征

提取方法仍存在性能高度依赖参数设置等缺陷，且对瞬时能量变化的捕捉能力不足。

近年来，随着深度学习技术的不断发展，越来越多的研究者将其应用于高阻抗故障诊断与定位，以进一步提升诊断精度。文献[21]针对高阻抗间歇性故障，采用 8 种有监督方法进行故障检测、分类和识别，结果表明机器学习分类器在 3 个目标中都具有最佳性能。针对配电网结构越来越复杂导致的高阻抗故障越来越难诊断的问题，文献[22]提出一种数据驱动的柯西分布加权 M 估计随机向量功能链路网络方法，用于实现复杂网络中高阻抗故障分类。文献[23]通过 EMD 提取电流信号中的多个特征，并采用长短期记忆网络对高阻抗故障与各种切换事件进行分类。DG 的接入给高阻抗故障诊断与定位带来了更大的挑战，由于 DG 并网时逆变器产生高频开关谐波，且其提供的短路电流幅值受限，因此容易导致高阻抗故障信号被淹没。基于上述考虑，文献[24]提出一种基于混合卷积神经网络的有源配电网高阻抗故障检测方法。文献[25]提出一种基于 t 分布随机邻域嵌入和变分模态分解的配电网高阻抗故障检测与定位方法，以解决测量设备引入噪声导致的故障特征信号被淹没的问题。然而上述采用深度学习实现配电网故障诊断的方法，虽然能够通过特征数据预测故障标签与故障线路，但存在解释性不足的问题。

基于上述研究与分析，为解决光伏并网导致配电网中谐波和噪声增加，高阻抗微弱故障信号特征难以捕捉的问题，本文提出一种基于 ZOA-MVMD-TKEO-STGCN 的光伏配电网高阻抗故障诊断与定位模型。首先，提出一种基于斑马优化(zebra optimization algorithm, ZOA)的多元变分模态分解(multivariate variational mode decomposition, MVMD)方法对输入信号进行分解，通过 ZOA 对 MVMD 参数进行动态优化，显著提升对微弱特征的提取能力，并有效分离故障特征和谐波成分，减少光伏并网对高阻抗故障诊断与定位的干扰，同时多节点数据共享中心频率保持拓扑关联性，避免单一节点数据局限性。其次，对 MVMD 得到的第一个本征模态函数(intrinsic mode function, IMF)分量进行 Teager-Kaiser 能量算子(teager-kaiser energy operator, TKEO)特征增强，放大瞬态特征，并结合各个 IMF 分量、原始信号的电压电流幅值相位、零序电压与零序电流等特征构建多特征融合向量组，全面捕捉高阻抗故障特征。最后，采用时空图卷积神经网络(spatio-temporal graph convolutional network, STGCN)通过图卷积网络显

式建模配电网物理拓扑结构, 并结合长短期记忆网络模块抑制新能源并网带来的扰动, 采用 STGCN 网络对上述多特征融合向量组进行分类, 构建了 ZOA-MVMD-TKEO-STGCN 故障诊断与定位模型, 实现了高阻抗故障类型与故障位置的诊断, 并与其他神经网络结构进行对比, 进一步验证了本文方法的优越性。

## 1 基于 ZOA-MVMD-TKEO-STGCN 的故障诊断与定位框架

由于高阻抗故障故障电流小难以检测, 且随着光伏发电系统并网, 故障数据的波动性增大, 为了充分挖掘故障特征并实现故障节点的检测, 本文采用 MVMD 对多变量信号进行模态分解, 采用 ZOA 方法优化 MVMD 的惩罚因子和分解层数, 并对分解后的第一个分量进行特征增强, 以进一步捕捉故障引起的瞬时能量变化, 最后将配电网拓扑信息与特征向量融合, 输入 STGCN 进行训练, 得到故障诊断结果, 具体步骤如下。

1) 首先对采集的原始数据进行处理, 提取包括电压和电流的幅值、相位及其对应的导数, 以及零序电压和零序电流, 共同构成特征向量。

2) 采用 ZOA 算法对 MVMD 的惩罚因子和分解层数进行参数寻优, 并对原始数据中每个节点的电流信号进行分解得到  $n$  个 IMF 分量。

3) 选取分解后的第一个 IMF 分量, 采用 TKEO 进行特征增强, 并将增强后的分量与 MVMD 分解后的各个分量以及电压电流信号、相位、幅值导数和相位导数结合, 构建多特征融合的特征向量组。

4) 将配电网拓扑结构与特征向量输入到 STGCN 网络中进行训练, 并根据故障分类准确率对模型进行评价。

基于 ZOA-MVMD-TKEO-STGCN 的故障诊断与定位模型整体框图如图 1 所示。

## 2 算法模型介绍

### 2.1 MVMD 原理

当发生高阻抗故障时, 故障电流接近正常负荷水平, 且随着光伏的接入, 故障波形表现出较强的非平稳性, 此外在故障特征提取过程中, 通常需要采集多个节点的电压和电流数据进行分析。然而传统方法难以有效捕捉此类非平稳、多变量信号的特征。MVMD 是一种用于从多元时间序列数据中提取模态成分的方法, 其核心是通过构建一个变分优化模型将多通道信号分解为多个联合窄带模态分量,

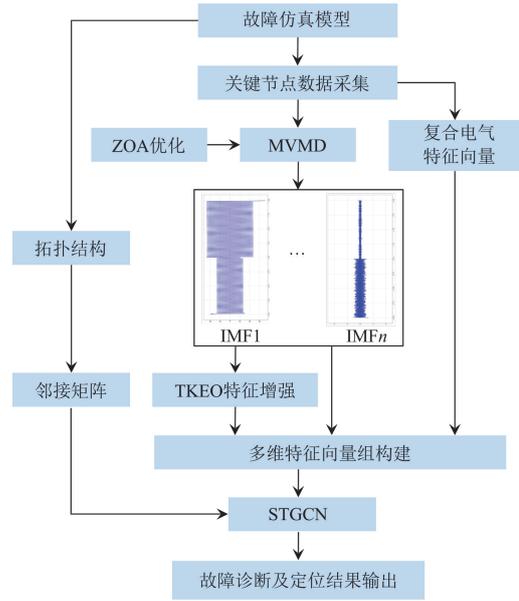


图 1 ZOA-MVMD-TKEO-STGCN 的故障诊断与定位模型整体框图

Fig. 1 Overall block diagram of the ZOA-MVMD-TKEO-STGCN based fault diagnosis and location model

同时约束所有通道的同一模态分量共享相同的中心频率, 其优化目标函数如式(1)所示。

$$\min_{\{u_{k,n}\}, \{\omega_k\}} \sum_{n=1}^N \left\| x_n - \sum_{k=1}^K u_{k,n} \right\|^2 + \alpha \sum_{n=1}^N \sum_{k=1}^K \left\| \partial t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_{k,n} \right] e^{-j\omega_k t} \right\|^2 \quad (1)$$

式中:  $t$  为时间变量;  $N$  为信号通道数;  $K$  为预设分解模态数;  $\alpha$  为带宽模态因子;  $\delta(t)$  为狄拉克函数;  $x_n$  为输入第  $n$  通道的信号;  $u_{k,n}$  为第  $n$  通道的第  $k$  个模态分量;  $\omega_k$  为所有通道共享的全局中心角频率; “\*” 表示卷积运算。

MVMD 通过交替方向乘子法迭代更新模态分量与中心频率, 直至收敛, 从而最小化所有模态的带宽总和, 迫使各模态在时频域紧密聚集, 首先将时域信号转换到频域, 表示为

$$\hat{u}_{k,n}^{(m+1)}(\omega) = \frac{\hat{x}_n(\omega) - \sum_{i \neq k} \hat{u}_{i,n}^{(m)}(\omega) + \hat{\lambda}_n^{(m)}(\omega)}{1 + 2\alpha(\omega - \omega_k^{(m)})^2} \quad (2)$$

式中:  $m$  为迭代次数;  $\omega$  为角频率;  $\hat{\lambda}_n^{(m)}$  为拉格朗日乘子的傅里叶变换;  $\hat{x}_n$  为原始信号  $x_n$  的傅里叶变换;  $\hat{u}_{k,n}^{(m+1)}$  为第  $n$  通道的第  $k$  个模态分量在第  $m+1$  次迭代更新后的傅里叶变换。

之后通过加权平均所有通道的频谱重心, 确保

多通道频率对齐, 更新中心频率公式为

$$\omega_k^{(m+1)} = \frac{\sum_{n=1}^N \int_0^\infty \omega |\hat{u}_{k,n}^{(m+1)}(\omega)| d\omega}{\sum_{n=1}^N \int_0^\infty |\hat{u}_{k,n}^{(m+1)}(\omega)| d\omega} \quad (3)$$

拉格朗日乘子更新公式和其收敛条件分别如式(4)、式(5)所示。

$$\hat{\lambda}_n^{(m+1)}(\omega) = \hat{\lambda}_n^{(m)}(\omega) + \tau(\hat{x}_n(\omega) - \sum_{k=1}^K \hat{u}_{k,n}^{(m+1)}(\omega)) \quad (4)$$

$$\sum_{k=1}^K \frac{\|\hat{u}_{k,n}^{(m+1)} - \hat{u}_{k,n}^{(m)}\|^2}{\|\hat{u}_{k,n}^{(m)}\|^2} < \varepsilon \quad (5)$$

式中:  $\tau$  为步长, 实际设置为 1;  $\varepsilon$  为预设收敛容差。

## 2.2 ZOA 原理

针对 MVMD 分解中惩罚因子与分解层数参数敏感性的问题, 本文采用 ZOA 策略进行优化, 从而增强 MVMD 提取低频微弱特征与保持跨通道频率一致性的能力, 实现多变量信号的精准分解。ZOA 通过模拟自然界中斑马的群体行为求解优化问题, 算法主要分为觅食行为阶段和防御策略阶段。在 ZOA 过程中, 种群中最优的成员为先锋斑马, 将其其他种群成员引向其所在搜索空间中的位置, 对于第  $i$  个个体的第  $j$  维位置, 其初始值表示为

$$x_{i,j} = b_j^l + r(b_j^u - b_j^l) \quad (6)$$

式中:  $b_j^l$ 、 $b_j^u$  分别为第  $j$  维变量的下界与上界;  $r$  是在 0~1 区间的随机数。

觅食行为阶段首先计算所有个体的适应度值, 并通过最优个体引导群体向高适应度区域移动, 实现全局探索。每个个体位置的更新公式为

$$x_{i,j}^{\text{new,P1}} = x_{i,j} + r(Z_j - Ix_{i,j}) \quad (7)$$

式中:  $x_{i,j}^{\text{new,P1}}$  为觅食阶段更新的新位置;  $Z_j$  为第  $j$  维中最优个体的位置;  $I$  为扰动因子, 在 1~2 之间随机取值。

当新位置适应度值高于原位置时, 对其进行位置更新。在防御行为阶段, 个体采用逃跑与进攻两种策略, 且每种策略的触发概率均为 50%, 以增强局部开发能力。在逃跑策略中, 个体的位置更新公式为

$$x_{i,j}^{\text{new,P2}} = x_{i,j} + R(2r-1)(1-\frac{m}{T})x_{i,j} \quad (8)$$

式中:  $x_{i,j}^{\text{new,P2}}$  为防御阶段更新的新位置;  $R$  为控制移动幅度, 取 0.01;  $T$  为最大迭代次数。

在进攻策略中个体位置更新公式为

$$x_{i,j}^{\text{new,P2}} = x_{i,j} + r(Q_j - Ix_{i,j}) \quad (9)$$

式中:  $Q_j$  为被攻击个体的位置。

ZOA 实现 MVMD 算法参数优化的流程图如图 2 所示, 其中  $P$  表示在逃跑策略与进攻策略中选择其中一种的概率。

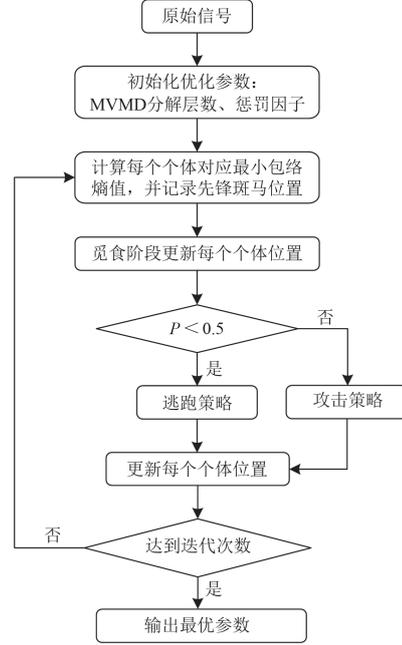


图 2 ZOA-MVMD 参数优化流程图

Fig. 2 Flowchart of ZOA-MVMD parameter optimization

## 2.3 TKEO 原理

TKEO 是一种分析非线性、非平稳信号的瞬时能量和频率信息的方法, 其核心原理是通过信号的一阶或二阶导数来计算其能量, 从而能够快速响应信号的瞬时变化。通过 TKEO 对 MVMD 的最高频本征模态分量(IMF1)进行增强, 能够更准确地捕捉信号中的高频瞬态成分, 减少模态混叠以及噪声的干扰。TKEO 对离散信号  $s(n)$  定义为

$$\Psi[s(n)] = s^2(n) - s(n-1)s(n+1) \quad (10)$$

## 2.4 STGCN 原理

长短期记忆网络(long short-term memory, LSTM)在传统递归神经网络的基础上, 引入了记忆细胞、输入门、输出门和遗忘门的概念。通过记忆细胞存储重要信息, 输入门决定是否记忆输入信息, 遗忘门控制当前信息的遗忘程度, 输出门决定记忆细胞中信息的输出, 使 LSTM 能够有效避免传统 RNN 中常见的梯度消失与梯度爆炸问题, 能够更好地捕捉和利用时间序列数据中的长期依赖关系。此外, LSTM 模型的参数在所有时间步骤上是共享的, 因而 LSTM 能够适应不同长度的序列数据, 并学习到不同层次的抽象特征。

图卷积神经网络(graph convolutional network, GCN)是图神经网络的一种变体,其核心是将卷积操作从欧几里得数据推广到图数据,其模型通过邻域聚合机制来学习节点的向量表示,即每个节点的表示不仅由自身特征决定,还通过与其相邻节点的信息交互来进行更新,并且 GCN 利用邻接矩阵,显式地对节点间的拓扑关系进行建模,并通过多层非线性变换逐步捕获多阶邻域信息,形成层次化特征表达。其数学公式为

$$\mathbf{H}^{(l+1)} = \sigma(\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{H}^{(l)} \mathbf{W}^{(l)}) \quad (11)$$

式中:  $\mathbf{H}^{(l)}$  为第  $l$  层的节点特征矩阵;  $\tilde{\mathbf{A}}$  为添加自连接的邻接矩阵;  $\tilde{\mathbf{D}}$  为  $\tilde{\mathbf{A}}$  的度矩阵,用于表示节点度数;  $\mathbf{W}^{(l)}$  为可学习的权重矩阵;  $\sigma(\cdot)$  为激活函数。

在配电网故障分类过程中,邻接矩阵用于表示配电网各个节点的拓扑结构,  $A_{c,v}=1$  表示节点  $c$  与节点  $v$  相连。输入层输入每个节点构建的特征向量组,输出层输出经过学习后的分类结果。

STGCN 是一种融合时间序列分析与图结构建模的框架,该框架首先将包含时空信息的 3 维数据转换为 2 维,并输入 LSTM 层,通过门控机制捕捉长期依赖关系,生成包含时序动态信息的隐藏状态,之后将时序特征提取后的数据还原为 3 维,并将包含配电网拓扑结构信息的邻接矩阵输入 GCN 中,以捕捉各个节点间的空间拓扑关系,引入残差连接机制以保留原始特征与高阶特征的互补信息,实现时空特征的联合建模,提升故障分类的准确率,STGCN 模型框架如图 3 所示。

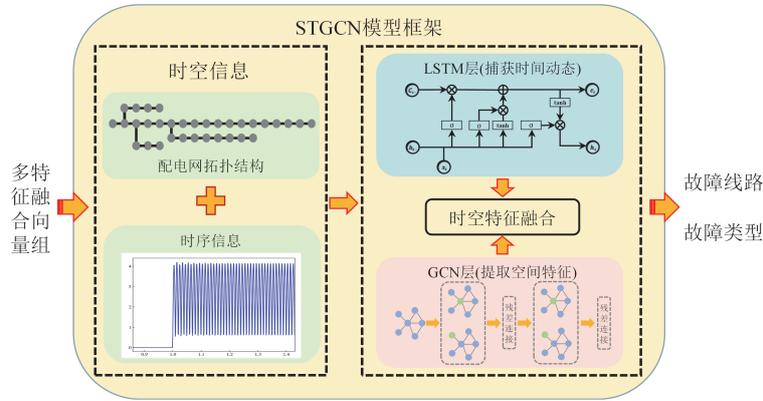


图 3 STGCN 模型框架

Fig. 3 Framework of the STGCN model

### 3 仿真验证

#### 3.1 数据来源

本文基于 IEEE33 节点配电系统进行实验验证,IEEE33 节点系统是配电网研究中广泛采用的基准模型,其设计兼顾了结构精简性与功能完备性,能够有效支持智能配电系统的实时分析与控制需求<sup>[26]</sup>。该系统由 33 条母线和 32 条线路构成,所有母线均在 12.66 kV 电压下运行,网络总功率为 3.715 MW 和 2.3 Mvar<sup>[27]</sup>。实验中应用 Simulink 仿真软件对 IEEE33 节点系统进行建模,并采集各个节点的电压与电流数据。考虑电压支撑需求,选择电压较低的末端节点接入光伏发电系统,以改善电压分布,因此仿真中将其分别接入到节点 17、21、24 与节点 32 处,IEEE33 节点系统拓扑结构以及光伏发电系统接入位置如图 4 所示。

实验中分别模拟单相接地故障、两相相间故障、两相接地故障、三相相间故障以及三相接地故障 5

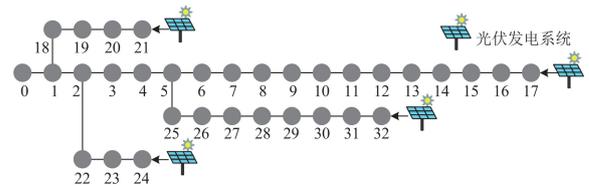


图 4 IEEE33 节点系统拓扑结构

Fig. 4 Topology of the IEEE 33-node system

种故障状态构建故障诊断数据集,并在 IEEE33 节点系统中的 32 条线路上分别设置上述故障,每条故障线路编号作为一种故障状态类型,以构建故障定位数据集。本实验设置采样频率为 100 kHz,高阻抗故障电阻为 500  $\Omega$ ,针对每条故障线路,每种状态下每个节点均采集 1 s 数据,共计 100 000 个点,由于电流电压波形每个周期对应 2000 个采样点,为提升数据计算效率,并保持原始信号的时序相关性特征,对每 1000 个连续采样点进行均值计算,以实现数据降维。

### 3.2 改进 MVMD 与特征增强

为了有效挖掘高阻抗故障中的故障特征，实验中对 6 种状态下的仿真数据进行电压相位、电流相位、零序电流以及零序电压计算，首先将原始信号  $x_n$  进行希尔伯特变换，见式(12)。

$$\hat{x}_n = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x_{\theta}}{n - \theta} d\theta \quad (12)$$

式中： $\theta$  为积分变量。

之后计算瞬时相位，表示为

$$\phi(t) = \arctan\left(\frac{\hat{x}(t)}{x(t)}\right) \quad (13)$$

以节点 1、节点 5 与节点 20 采集的单相接地故障(故障发生在节点 8-9 之间)为例，绘制故障相电流幅值的时域图及零序电流变化图像，如图 5 所示，其中前 1 s 为正常运行，在 1 s 时添加高阻抗故障。

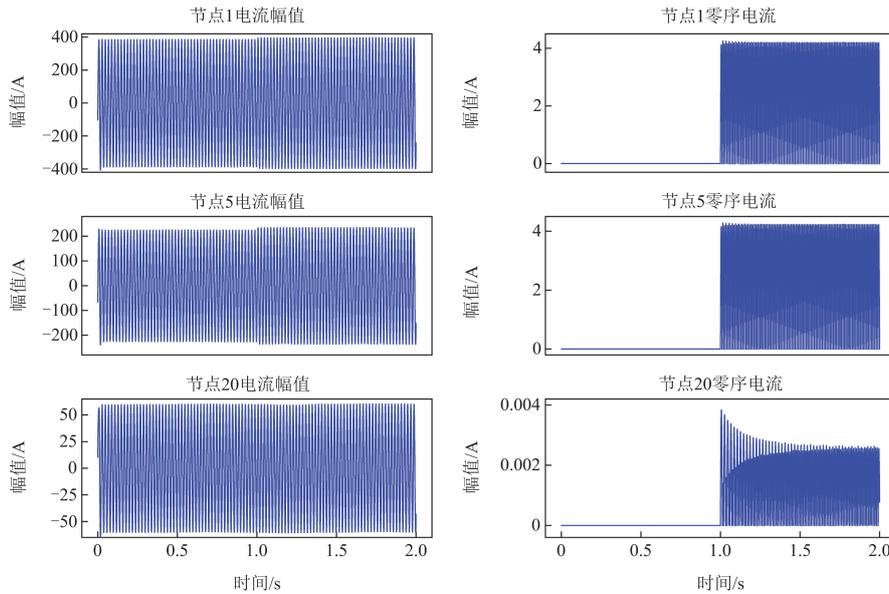


图 5 故障相电流幅值及零序电流随时间变化曲线

Fig. 5 Curves of fault-phase current amplitude and zero-sequence current vs. time

由图 5 中的故障相电流幅值及零序电流变化曲线分析可知，当 1 s 配电网发生高阻抗故障时，由于故障电阻较大，3 个节点的电流幅值波动较小，导致基于幅值突变的传统检测方法难以有效检测故障。然而，零序电流分量表现出显著的异常波动，可以明显判断是否发生故障，因此通过零序电流和零序电压的计算可以辅助判别故障。但是仅依赖零序电流作为特征向量，难以有效实现故障辨识。此外，随着光伏的接入，配电网出现相位偏移和多元干扰等问题，进一步降低了零序电流在故障诊断与定位中的可靠性，因此还需对故障特征进行多维深度挖掘。

由于光伏发电的不确定性以及逆变器等并网设备的非线性特性，配电网在引入光伏发电系统后会其功率波动增大并产生谐波，这使得配电网故障信号特性变得更加复杂，影响故障分类效果。因此实验中针对多节点的电流信号进行 MVMD 分解，并采用 ZOA 对惩罚因子和分解层数进行参数优化，具体实验设置如下：设置 ZOA 迭代次数为 20 次，惩罚因子的寻优范围为[100, 10 000]，分解层数寻优

范围为[3, 10]，设置最小包络熵作为适应度函数，ZOA 寻优过程中适应度函数值随迭代次数变化曲线如图 6 所示。

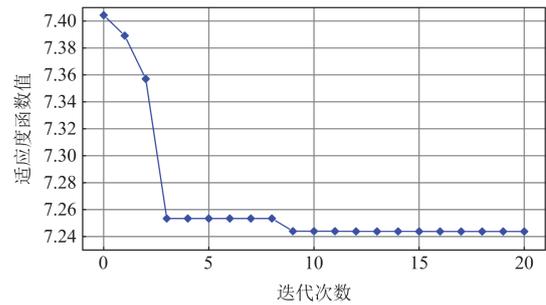


图 6 适应度函数值随迭代次数变化曲线

Fig. 6 Curves of fitness function vs. iterations

由图 6 可以看出，随着迭代次数增加，适应度函数值不断下降，并在迭代次数达到 9 次后，适应度函数值达到稳定，说明此时参数已经到达最优，最终得到最优取值为惩罚因子值为 9427、分解层数为 6 层。设置最优参数，同时对 6 个数据采集节点的电流数据进行 MVMD，并以单相接地故障为例，

绘制分解后节点 1、5 与 20 各分量的时域图, 纵坐标表示幅值, 单位为 A, 如图 7 所示。

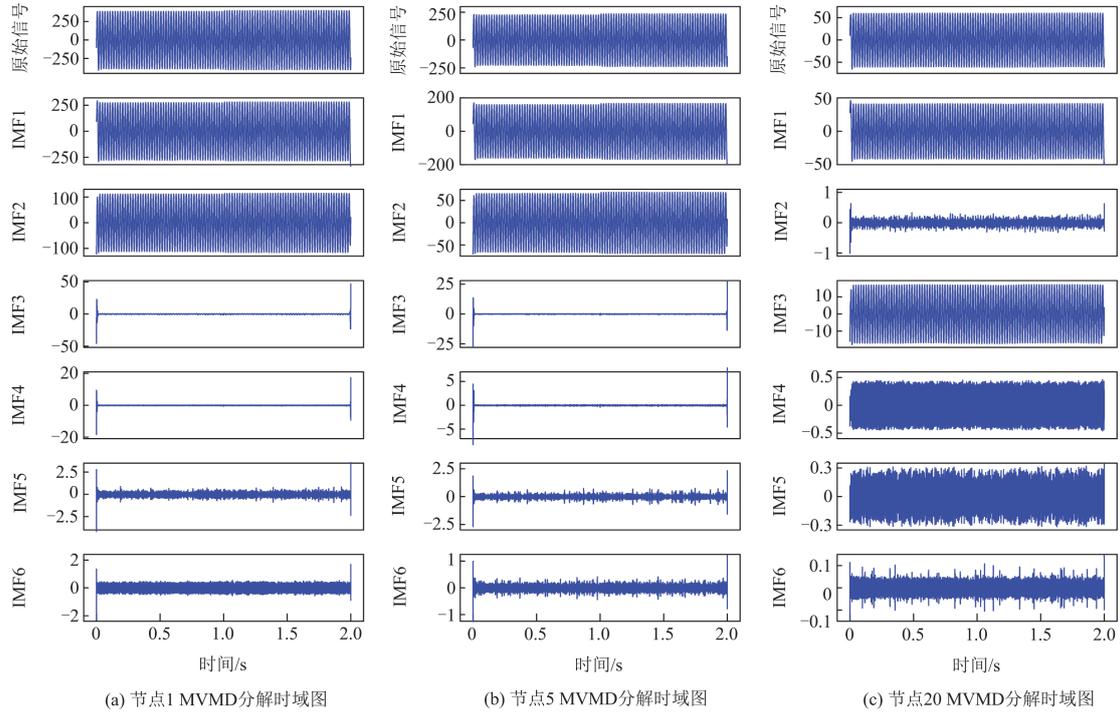
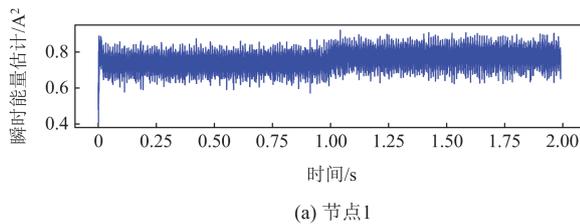


图 7 单相接地故障下节点 1、5、20 MVMD 分解结果

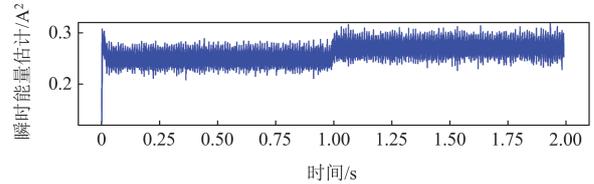
Fig. 7 MVMD decomposition results of nodes 1, 5, and 20 under single-phase ground fault

由图 7 可以看出, 当 1 s 发生单相接地故障时, 节点 1、节点 5 和节点 20 的电流发生极小幅度的波动, 这是由于高阻抗故障电流较小, 同时光伏发电系统在末端接入, 当发生故障时, 通过局部供电和无功补偿抑制故障下游节点电流的下降, 因此增大了故障诊断与定位的难度。经过 MVMD 分解, 所有节点的 IMF 分量模态分解结构清晰, 相邻 IMF 分量无明显的重叠, 同时分解后的 IMF 分量也可以很好地捕捉瞬态特征, 并对环境噪声进行初步分离, 之后采用 TKEO 对各个节点第一个 IMF 分量进行特征增强, 特征增强后的时域图如图 8 所示。

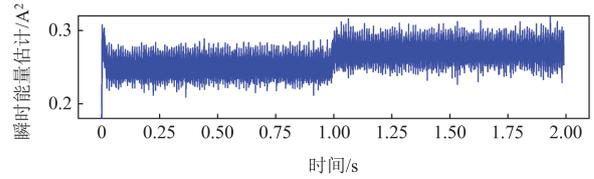
由图 8 可以看出, 对各个节点 IMF1 分量进行 TKEO 特征增强后, 其瞬态成分显著增加, 在 1 s 故障发生时, 所有节点均出现幅值突增现象, 同时非故障情况下, 波形幅值保持稳定, 说明 TKEO 具有一定的噪声抑制能力。分别将各节点的 TKEO 增强特征、MVMD 分解得到的 IMF 分量以及复合



(a) 节点1



(b) 节点5



(c) 节点20

图 8 单相接地故障下节点 1、5、20 TKEO 特征增强结果

Fig. 8 TKEO-based feature enhancement results of nodes 1, 5, and 20 under single-phase ground fault

电气特征进行融合, 构建多特征融合的特征向量组, 输入到 STGCN 中实现高阻抗故障诊断与定位。

### 3.3 对比实验

为了验证本文方法在光伏配电网高阻抗故障诊断中的性能, 采用 LSTM、EMD-DRSN 以及经验小波变换与混合卷积递归神经网络<sup>[28]</sup>3 种深度学习故障诊断模型进行实验对比。实验将多特征融合向量组输入 STGCN 中分别实现高阻抗故障诊断与定

位。故障类别辨识过程中设置正常状态标签为 0，单相接地故障标签为 1，两相相间故障标签为 2，两相接地故障标签为 3，三相相间故障标签为 4，三相接地故障标签为 5；故障定位过程中设置标签为故障发生线路的编号。选择交叉熵作为损失函数，以学习更具鲁棒性的特征表示，并有效地训练网络以提高分类准确率。模型训练的迭代次数为 3000 次，选择 Adam 算法作为优化算法，训练集设置为总样本的 70%，测试集设置为总样本的 20%，验证集设置为总样本的 10%，为了评估学习率对模型性能的影响，本文在上述参数条件下进行预实验，分别设置学习率为 0.01、0.005、0.001、0.0005 进行独立训练，并以模型故障诊断与定位的准确率作为评价标准，实验结果如图 9 所示。

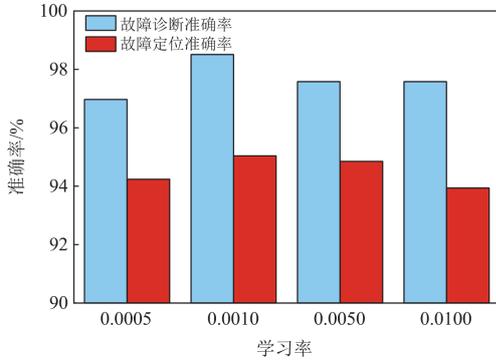


图 9 故障诊断与定位准确率随学习率参数变化曲线

Fig. 9 Curves of fault diagnosis and localization accuracy vs. learning rate parameters

由图 9 可知，与设置的其他学习率相比，当学习率设置为 0.001 时，模型故障诊断与故障定位准确率均更高，这是由于过大的学习率可能忽略故障特征的局部相关性，而过小的学习率则无法有效捕捉节点间关联的动态特性，因此本文选择学习率为 0.001 进行后续实验。故障诊断过程中损失函数值和故障诊断准确率随迭代次数的变化曲线如图 10 所示。

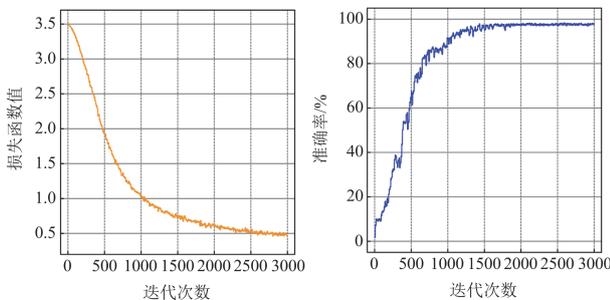


图 10 损失函数值及故障诊断准确率随迭代次数变化

Fig. 10 Curves of loss function value and fault diagnosis accuracy vs. iterations

由图 10 可以看出，随着迭代次数的增加，故障识别准确率逐渐提升，同时损失值逐渐下降并收敛达到稳定，说明此时模型为最佳状态。在最佳参数下，使用相同数据集进行 5 次对比实验，并计算其平均值，作为故障诊断的最终准确率。ZOA-MVMD-TKEO-STGCN 模型故障分类效果如图 11 所示，4 种方法的分类准确率对比如表 1 所示。

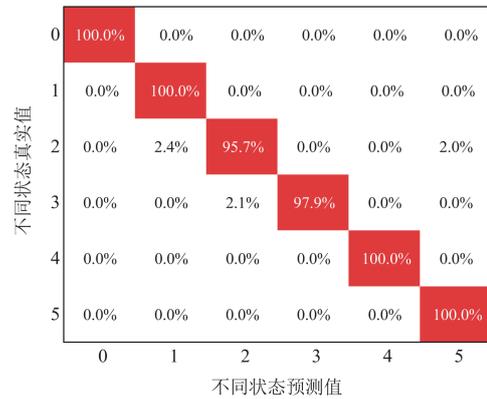


图 11 ZOA-MVMD-TKEO-STGCN 模型故障分类效果图

Fig. 11 Fault classification performance of the ZOA-MVMD-TKEO-STGCN model

表 1 4 种方法不同特征状态分类准确率对比

Table 1 Comparison of classification accuracy for four methods under different feature states

特征状态	LSTM	EMD-DRSN	EWT-HCRNN	本文方法
正常	98.27	98.54	100	99.68
单相接地	94.48	98.12	95.83	100
两相相间	97.50	96.04	96.86	95.86
两相接地	91.16	94.23	95.51	95.84
三相相间	94.11	96.15	98.46	99.68
三相接地	100	100	100	100
综合识别率	95.92	97.18	97.78	98.51

由图 11 和表 1 可以看出，相较于传统深度学习方法，本文方法对光伏配电网中的高阻抗故障诊断准确率更高。尽管 LSTM 方法对正常与三相接地故障状态较为敏感，但其对于单相接地、两相接地故障以及三相相间故障的诊断准确率均较低。相比之下，采用 EMD 结合 DRSN 网络以及 EWT 分解结合 HCRNN 网络的方法能够有效提升高阻抗故障诊断的效果，综合识别率分别为 97.18%、97.78%，而本文方法在此基础上准确率分别提升了 1.33%、0.73%，由于相较于 EMD 及 EWT，MVMD 可以更加有效地减少模态混叠，且具有更强的抗噪性，优化 ZOA 参数后，在噪声环境下的特征提取效果得到显著提升，而 TKEO 通过瞬态特征增强策略，有

效捕捉故障瞬时能量变化, 最后 STGCN 有效挖掘时序故障特征以及配电网拓扑关联特性, 解决光伏并网带来的谐波耦合等问题, 以消除其对故障诊断的影响。4 种方法的故障定位准确率对比结果如表 2 所示, 故障定位准确率对比曲线如图 12 所示。

表 2 4 种方法不同特征状态故障定位准确率比较

Table 2 Comparison of fault location accuracy for four methods under different feature states

特征状态	LSTM	EMD-DRSN	EWT-HCRNN	本文方法
单相接地	86.57	90.32	90.52	94.12
两相相间	88.48	90.22	90.31	91.82
两相接地	89.50	91.86	93.33	93.50
三相相间	89.80	88.28	92.71	95.76
三相接地	97.58	96.77	96.46	100
综合识别率	90.39	91.49	92.67	95.04

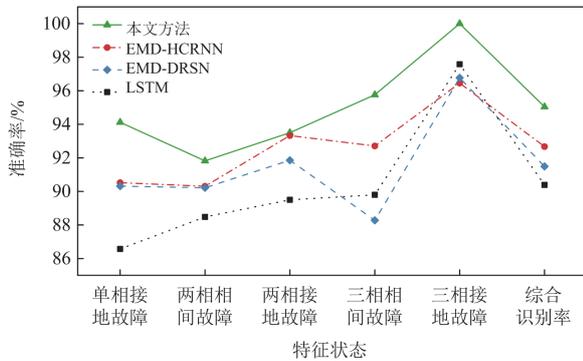


图 12 不同方法故障定位准确率对比

Fig. 12 Comparison of fault location accuracy for different methods

由图 12 和表 2 可以看出, 相较于其他深度学习方法, 本文方法在各种光伏配电网高阻抗故障状态下的故障定位准确率均最高。在最常见的配电网单相接地故障中, 对比方法故障定位准确率均偏低, 最高仅为 90.52%, 而本文方法的故障定位准确率为 94.12%, 同时本文方法的故障定位综合识别率也比上述最优的传统方法提升了 2.3% 以上, 为了验证本文方法在不同阻抗值下的鲁棒性, 开展了 200  $\Omega$ 、300  $\Omega$ 、400  $\Omega$  与 500  $\Omega$  4 组高阻抗故障诊断与定位实验, 不同阻抗值下的性能对比如表 3 所示。

表 3 不同阻抗值下故障诊断与定位性能对比

Table 3 Performance comparison of fault diagnosis and localization under different impedance values

阻抗值/ $\Omega$	200	300	400	500
故障诊断	99.72%	99.13%	98.63%	98.51%
故障定位	96.38%	95.74%	95.25%	95.04%

由表 3 可知, 随着阻抗值增大, 故障特征提取难度显著增加, 本文方法通过自适应特征提取机制, 能够有效克服阻抗增大导致的特征衰减问题, 始终保持优异的诊断性能, 因此实验结果表明, 在光伏并网产生谐波与噪声干扰的复杂场景下, 本文方法能更有效地诊断和定位高阻抗故障。

### 3.4 消融实验

为了进一步验证改进 MVMD 特征增强结合 STGCN 方法在光伏配电网高阻抗故障诊断与定位中的优越性, 开展消融实验设置如下: 1) 根据原始电流电压信号计算相位、零序电流以及零序电压, 并将其作为特征向量, 输入 STGCN 网络进行故障诊断与定位; 2) 对原始电流信号进行 ZOA-MVMD 分解, 并将第一个 IMF 分量进行特征增强, 融合相位、零序电流及零序电压信息, 输入 GCN 网络实现故障诊断与定位; 3) 本文方法构建 ZOA-MVMD-TKEO-STGCN 模型实现故障诊断与定位, 实验结果分别如图 13、图 14 所示。

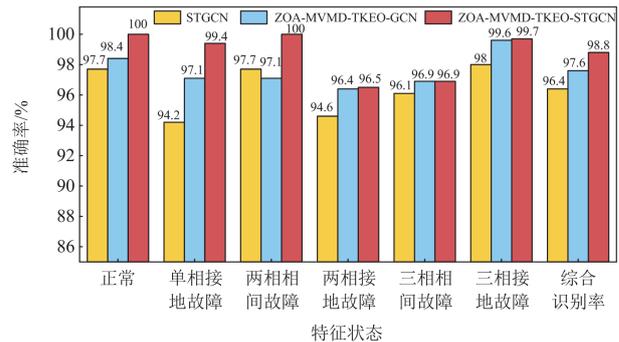


图 13 不同模型故障诊断精度比较

Fig. 13 Comparison of fault diagnosis accuracy for different models

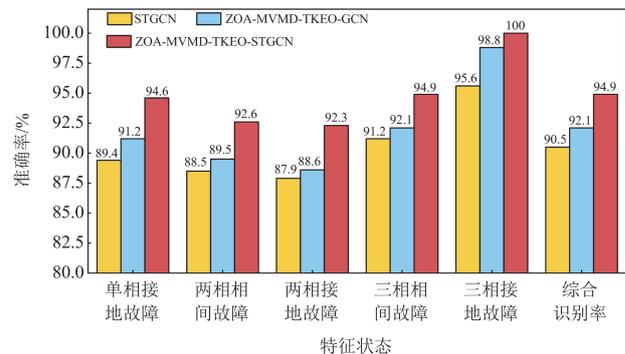


图 14 不同模型故障定位精度比较

Fig. 14 Comparison of fault location accuracy for different models

由图 13 与图 14 可知, 相较于未经过 MVMD 分解以及特征增强的特征向量, 采用 ZOA-MVMD-

TKEO方法构建的多特征融合特征向量组的故障诊断与定位精度均更高,说明经过ZOA-MVMD-TKEO处理后,多维特征向量组可以更好地捕捉微弱的高阻抗故障特征,并且减少光伏并网所产生的干扰。相比于ZOA-MVMD-TKEO-GCN模型,ZOA-MVMD-TKEO-STGCN模型的综合识别率更高,达到了98.8%,并且故障定位的准确率也提升了2.8%,通过对时空特征的融合学习,STGCN可以更好地挖掘高阻抗故障特征实现故障诊断。综上所述,通过消融实验验证,ZOA-MVMD-TKEO方法构建的多特征融合向量能有效提取高阻抗故障特征。同时,也证实了STGCN模型在光伏配电网高阻抗故障诊断与定位中的优越性。

#### 4 结论

配电网中高阻抗故障故障电流较小,导致传统保护方法难以有效检测,且光伏并网对电能质量的影响较为显著,由于光伏并网过程中逆变器开关频率高,使得配电网中谐波含量增大,同时新能源出力具有较强的波动性与随机性,导致配电网中高阻抗故障信号特征难以捕捉,因此本文针对光伏配电网高阻抗故障诊断与定位展开了研究,通过算例分析得到以下结论。

1) 将光伏配电网多节点高阻抗故障数据经由ZOA优化的MVMD分解后,选择IMF1分量进行TKEO特征增强,并构建多特征融合向量组,将原始信号中的故障特征与谐波成分进行分离,增强了瞬态特征,提升了特征向量的质量。

2) 将多特征融合向量组输入STGCN进行训练,STGCN通过对时序动态特征以及配电网拓扑结构的学习,更好地捕捉高阻抗故障特征,提升了故障诊断与定位精度。

3) 实验结果表明,本文构建的ZOA-MVMD-TKEO-STGCN模型相较于传统的故障诊断模型,在光伏配电网高阻抗故障诊断与定位上均有更高的准确率,性能上具有显著的优越性。

4) 在工程应用层面,针对高阻抗故障风险区域,本文方法通过同步相量测量装置实时同步采集关键节点的高精度波形数据,并由调度中心进行实时故障诊断与定位,同时,所采用的动态拓扑适应技术能有效适应新能源接入与网络重构等复杂场景,因此本文方法在光伏接入配电网的高阻抗故障诊断与定位方面,具有广阔的应用前景。

#### 参考文献

[1] IBRAHIM A H M, SADANANDAN S K, GHAUD T,

- et al. Incipient fault detection in power distribution networks: review, analysis, challenges and future directions[J]. IEEE Access, 2024, 12: 112822-112838.
- [2] 李纳纳, 王宾. 小电流接地配电网馈线单相接地故障零序阻抗特性分析[J]. 电测与仪表, 2024, 61(6): 58-64. LI Nana, WANG Bin. The analysis of zero-sequence impedance characteristics of feeder in distribution system with neutral point non-effective grounding[J]. Electrical Measurement & Instrumentation, 2024, 61(6): 58-64.
- [3] 李辉, 李航, 陈尚, 等. 配电网单相接地故障电弧特性分析及真型试验技术研究[J]. 供用电, 2024, 41(4): 45-52. LI Hui, LI Hang, CHEN Shang, et al. Study on arc characteristics of single-phase grounding fault and true type test technology in distribution network[J]. Distribution & Utilization, 2024, 41(4): 45-52.
- [4] 刘硕, 刘灏, 毕天姝, 等. 考虑高阻接地的配电网故障检测方法[J]. 电网技术, 2023, 47(8): 3438-3448. LIU Shuo, LIU Hao, BI Tianshu, et al. Fault detection of distribution network considering high impedance faults[J]. Power System Technology, 2023, 47(8): 3438-3448.
- [5] ZIDAN A, KHAIRALLA M, ABDRABOU A M, et al. Fault detection, isolation, and service restoration in distribution systems: state-of-the-art and future trends[J]. IEEE Transactions on Smart Grid, 2016, 8(5): 2170-2185.
- [6] 罗国敏, 杨雪凤, 尚博阳, 等. 基于改进堆叠降噪自编码器的配电网高阻接地故障检测方法[J]. 电力系统保护与控制, 2024, 52(24): 149-160. LUO Guomin, YANG Xuefeng, SHANG Boyang, et al. High impedance grounding fault detection method of a distribution network based on an improved stacked denoised autoencoder[J]. Power System Protection and Control, 2024, 52(24): 149-160.
- [7] 杨鹏辉, 钱国超, 白浩, 等. 参数不对称配电网高阻接地故障感知与辨识方法[J]. 中国电力, 2025, 58(2): 22-32. YANG Penghui, QIAN Guochao, BAI Hao, et al. High resistance grounding fault perception and identification method in asymmetric distribution network[J]. Electric Power, 2025, 58(2): 22-32.
- [8] 刘晓庆, 王铁, 刘坤, 等. 考虑分布式光伏的配网谐振接地故障辨识与定位[J]. 可再生能源, 2025, 43(4): 528-533. LIU Xiaoqing, WANG Tie, LIU Kun, et al. Research on fault diagnosis technology of resonant grounding system considering distributed photovoltaic access[J]. Renewable Energy, 2025, 43(4): 528-533.
- [9] 许守东, 欧阳金鑫, 陈宇捷, 等. 基于模型识别的有源配电网单相接地故障定位方法[J]. 电力系统保护与控制, 2024, 52(5): 51-60. XU Shoudong, OUYANG Jinxin, CHEN Yujie, et al. A fault location method for a single-phase fault for a distribution network with DGs based on model

- recognition[J]. *Power System Protection and Control*, 2024, 52(5): 51-60.
- [10] 柯亮, 李波, 廖凯, 等. 基于 XGBoost 的配电网高阻抗接地故障检测方法[J]. *电力系统保护与控制*, 2024, 52(6): 88-98.  
KE Liang, LI Bo, LIAO Kai, et al. High impedance fault detection method in a distribution network based on XGBoost[J]. *Power System Protection and Control*, 2024, 52(6): 88-98.
- [11] 田君杨, 李海勇, 蒋连钿, 等. 含多分布式电源的小电阻接地系统单相接地故障特征分析[J]. *电力系统保护与控制*, 2024, 52(14): 103-110.  
TIAN Junyang, LI Haiyong, JIANG Liandian, et al. Analysis of single-phase grounding fault characteristics of low resistance grounding system with multi-distributed power supply[J]. *Power System Protection and Control*, 2024, 52(14): 103-110.
- [12] GURURAJAPATHY S S, MOKHLIS H, ILLIAS H A. Fault location and detection techniques in power distribution systems with distributed generation: a review[J]. *Renewable and sustainable energy reviews*, 2017, 74: 949-958.
- [13] TANG R, ZHANG W. Gradient characteristics of fault impedance in distribution network of vegetation high-impedance fault[C] // 2024 7th Asia Conference on Energy and Electrical Engineering (ACEEE), July 20-22, 2024, Chengdu, China: 150-154.
- [14] 于华楠, 仇华华, 王鹤, 等. 基于改进半张量积贝叶斯网络的直流配电网故障诊断[J]. *电测与仪表*, 2025, 62(6): 178-185.  
YU Huanan, QIU Huahua, WANG He, et al. Fault diagnosis of DC distribution network based on improved matrix-half-tensor product Bayesian network[J]. *Electrical Measurement & Instrumentation*, 2025, 62(6): 178-185.
- [15] WEI M, SHI F, ZHANG H, et al. Wideband synchronous measurement-based detection and location of high impedance fault for resonant distribution systems with integration of DERs[J]. *IEEE Transactions on Smart Grid*, 2022, 14(2): 1117-1134.
- [16] LIANG D, XU B, WANG P, et al. Comprehensive study on tree-contact single-phase-to-ground faults: modelling, risk analysis, and detection recommendations[J]. *High Voltage*, 2024, 9(6): 1280-1287.
- [17] PANDEY A K, KISHOR N, MOHANTY S R, et al. A reliable fault detection algorithm for distribution network with DG resources[J]. *Electric Power Systems Research*, 2023, 223.
- [18] SHENG W, LIU K, JIA D, et al. An improved high-impedance fault identification scheme for distribution networks based on kernel extreme learning machine[J]. *International Journal of Electrical Power & Energy Systems*, 2024, 155.
- [19] YUAN J, HU Y, LIANG Y, et al. Faulty feeder detection for single line-to-ground fault in distribution networks with DGs based on correlation analysis and harmonics energy[J]. *IEEE Transactions on Power Delivery*, 2022, 38(2): 1020-1029.
- [20] LIN X, CHEN H, XU K, et al. Time estimation algorithm of single-phase-to-ground fault based on two-step dimensionality reduction[J]. *Energies*, 2023, 16(13).
- [21] HOJABRI M, NOWAK S, PAPAEMMANOUIL A. ML-based intermittent fault detection, classification, and branch identification in a distribution network[J]. *Energies*, 2023, 16(16).
- [22] HAYDAROLU C, BILAL G. Fault detection in distribution network with the Cauchy-M estimate—RVFLN method[J]. *Energies*, 2022, 16.
- [23] SHIHABUDHEEN K V, GUPTA S. Detection of high impedance faults in power lines using empirical mode decomposition with intelligent classification techniques[J]. *Computers and Electrical Engineering*, 2023, 109.
- [24] WANG C, FENG L, HOU S, et al. A high-impedance fault detection method for active distribution networks based on time-frequency-space domain fusion features and hybrid convolutional neural network[J]. *Processes*, 2024, 12(12).
- [25] YIN Z, ZHENG Y, WEI Z, et al. High-impedance fault section location for distribution networks based on T-distributed stochastic neighbor embedding and variable mode decomposition[J]. *Journal of Modern Power Systems and Clean Energy*, 2023, 12(5): 1495-1505.
- [26] BARAN M E, WU F F. Network reconfiguration in distribution systems for loss reduction and load balancing[J]. *IEEE Transactions on Power Delivery*, 1989, 4(2): 1401-1407.
- [27] SAVIER J S, DAS D. Impact of network reconfiguration on loss allocation of radial distribution systems[J]. *IEEE Transactions on Power Delivery*, 2007, 22(4): 2473-2480.
- [28] MAMPILLY B J, SHEEBA V S. An empirical wavelet transform based fault detection and hybrid convolutional recurrent neural network for fault classification in distribution network integrated power system[J]. *Multimedia Tools & Applications*, 2024, 83: 77445-77468.

收稿日期: 2025-05-16; 修回日期: 2025-11-15

作者简介:

李彬(1980—), 男, 硕士, 高级工程师, 研究方向为电力系统暂态稳定性评估、潮流分析、配电网络规划和配电网技术; E-mail: boylibin@126.com

孙玉树(1987—), 男, 通信作者, 博士, 副研究员, 研究方向为可再生能源发电、储能、微网及电网优化运行。E-mail: yushusun@mail.iee.ac.cn

(编辑 许威)