DOI:10.20033/j.1003-7241.(2025)07-0182-04

# 基于多源数据和图神经网络相结合的故障诊断模型在故障录波主站上的应用

郑少明[1]，董 鹏[1]，刘 丹[1]，宿洪智[1]，陈 吉[2]，郭明宇[2]

（1.国家电网有限公司华北分部，北京 100053；
2.武汉中元华电科技股份有限公司，湖北 武汉 430223）

**摘 要：**针对电力系统中传统的故障诊断方法主要依赖人工经验和刚性规则，在故障录波主站上提出基于多源数据和图神经网络相结合的故障诊断模型。首先对采集数据进行对齐、标准化和归一化等预处理，然后推导电网图形的谱域表达方式，再根据电网多源数据的不同特点进行针对性的特征提取和融合，最后通过算例验证该故障诊断模型的有效性。实验结果表明所提出的方法可以提高故障诊断的准确性和效率，减少对人力资源的依赖，从而更好地保障电力系统的安全稳定运行。

**关键词：**故障诊断模型；多源数据；图神经网络；录波主站

**中图分类号：**TP183；TM615 **文献标识码：**A **文章编号：**1003-7241(2025)07-0182-04

# Application of Fault Diagnosis Model Based on Multi-source Data and Graph Neural Network in the Fault Recorder Master Station

ZHENG Shaoming[1], DONG Peng[1], LIU Dan[1], SU Hongzhi[1], CHEN Ji[2], GUO Mingyu[2]

( 1. North China Branch of State Grid Corporation of China, Beijing 100053, China;
2. Wuhan Zhongyuan Huadian Science and Technology Co., Ltd.,Wuhan 430223, China )

**Abstract:** Aiming at the traditional fault diagnosis methods in power systems mainly rely on manual experience and rigid rules, this paper proposes a fault diagnosis model that combines multi-source data and graph neural network in the fault recording main station. Firstly, the acquired data is preprocessed through alignment, standardization and normalization, etc. Then, a spectral domain representation of the power grid topology is derived. Afterward, targeted feature extraction and fusion are conducted based on the different characteristics of the multi-source data of the power grid. Finally, the effectiveness of the fault diagnosis model is verified through an example calculation. The experiment result shows that the proposed model can improve the accuracy and efficiency of fault diagnosis, reduce dependence on human resources, and better guarantee the safe and stable operation of power systems.

**Keywords:** fault diagnosis model; multi-source data; graph neural network; recorder master station

## 0 引言

故障录波主站系统是电力系统重要的监测和故障诊断工具之一，可以采集、存储和分析电网状态和设备运行数据，并通过对这些数据进行自动处理和分析，实现电网的常态监测和异常情况的快速诊断[1]。随着电网规模和复杂度的不断增加，传统的故障诊断方法已经不能满足日益增长的需求。传统的故障诊断方法往往基于经验和专家知识，需要大量的人工干预和解释，而且易受主观因素的影响，导致准确度和效率都较低。因此，如何利用机器学习等新兴技术来改进故障诊断方法，成为了当前研究的热点之一[2-4]。

在这种背景下，有学者开展了将图神经网络应用于电网故障诊断的研究[5-6]。文献[5]研究了智能变电站中二次回路的故障定位问题，将种二次设备节点的信息表征作为图神经网络的输入。文献[6]考虑了配电网中的故障定位问题，并解决了其中的数据去噪难题。但以上研究均未充分考虑电力系统中丰富的多源异构数据，如录波数据、SOE信息和系统运行定值等。基于以上考虑，本文提出了一种基于多源数据和图神经网络（multi-source data and graph neural network，MDGNN）相结合的故障诊断模型，该模型将电网状态、设备参数和拓扑关系等信息以图形的形式进行表达，并在此基础上进行特征提取、分类和预测，以实现更加准确和稳定的故障诊断。

与传统的故障诊断方法相比，本文提出的MDGNN

*基金项目：国网华北分部华北电网故障录波主站系统功能完善化项目（SGNC0000DKXX2200134）

收稿日期：2023-09-21

模型具有以下优势：可以自主从历史数据中学习和推理，不需要人工参与，从而减少了人力成本和时间成本；能够利用大量的历史数据进行训练和优化，从而实现更加准确和稳定的故障诊断；可以通过对实时数据的快速处理和分析，实现电网状态的实时监测和预测，从而提高了故障诊断的效率和及时性；根据不同的电网特点和故障场景，可以自主选择和优化模型结构和参数，从而实现更好的适应性和可扩展性。

## 1 数据采集与预处理

### 1.1 断面录波数据对齐

故障录波主站在采集到电网各节点的录波后，需要进行统一的时间对齐之后才能有效地对故障位置进行判断。然而，虽然绝大多数录波数据都经过了时钟装置的对时，但装置精度、环境干扰等因素依然导致不同的录波数据在绝对时间上存在差异。因此，在寻找同一断面录波时间时，首先利用数据时标进行粗对齐，再通过突变量查找算法[7]进行精细对齐。录波数据的突变量检测判据如下：

$$\|D(t+2N)-D(t+N)|-|D(t+N)-D(t)\| \geqslant K \times D_n \quad (1)$$

式中，$D(t)$为采样数据的瞬时值，$N$为每个周波的采样点数，K为突变系数，$D_n$为通道数据的额定值。为了保证系统在振荡状态下依然能准确捕捉暂态突变量，在突变量检测的同时也会辅以通道越限判据。

### 1.2 数据的标准化与归一化

由于同一网络中不同的录波装置生成的录波数据，在数据长度、采样率上都无法做到完全统一[8]；同时，不同电压等级的电网在采样绝对值大小上也存在差异。因此，有必要对数据进行标准化和归一化处理[9-10]。

（1）对故障设备录波波形，以故障起始时刻为分界点，取故障前两个周波和故障后十个周波电压电流波形数据，以及相应时间窗的保护和开关通道数据。

（2）为统一数据的时间尺度，对所有故障录波数据每个周波均取$N$个点，对不同采样率的数据利用牛顿插值法进行数据对齐。

（3）以采集电压电流的二次额定值为基准，对采集到的各录波数据以及保护定值数据通过线性变换进行归一化和标准化，有利于后续的特征提取过程。

## 2 电网图形的谱域表达

在建立电网图形的谱域表达前，首先需要图论对电网拓扑进行表示[5-6,11]。如图1所示，图G中包含节点数$n$=4，边数$m$=4，具体节点和边的集合$V$={$V1$, $V2$, $V3$, $V4$}，$E$={($V1$, $V2$), ($V1$, $V3$), ($V2$, $V3$), ($V3$, $V4$)}。

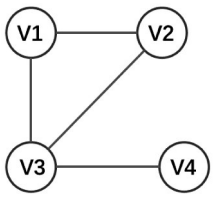



**图1 图G的拓扑结构**

图G的邻接矩阵和度矩阵分别为

$$\boldsymbol{A}=\begin{bmatrix}0&1&1&0\\1&0&1&0\\1&1&0&1\\0&0&1&0\end{bmatrix} \quad \boldsymbol{D}=\begin{bmatrix}2&0&0&0\\0&2&0&0\\0&0&3&0\\0&0&0&1\end{bmatrix} \quad (2)$$

式中，邻接矩阵$\boldsymbol{A}$是一个对称正定的方阵，表示图中节点间的连接关系，$\boldsymbol{A}$中元素为0表示对应节点无连接关系，元素为1表示节点间存在连接关系。度矩阵$\boldsymbol{D}$是一个对角矩阵，对角线上的元素表示各个节点的度，即与该节点连接的边的数量。

值得注意的是，判断电网线路故障时，通常需要关注的是线路两端采集的电气量状态。因此基于图论对电网建模时，把电力线路转化为图中的节点，这样既简化了模型，同时也保证了每个节点拥有相同的状态维度。

建立电网拓扑的图矩阵后，再将卷积神经网络（convolutional neural network，CNN）用于图的非欧式数据上，形成图卷积神经网络。其基本思想是，利用图的拉普拉斯矩阵$\boldsymbol{L}$的特征值和特征向量来导出频域上的拉普拉斯算子，再通过类比欧氏空间的傅里叶变换得到图上的傅里叶变换，从而可以得到图上的卷积表达。归一化的拉普拉斯矩阵$\overline{\boldsymbol{L}}$为

$$\overline{\boldsymbol{L}}=\boldsymbol{I}-\boldsymbol{D}^{-\frac{1}{2}}\boldsymbol{A}\boldsymbol{D}^{-\frac{1}{2}} \quad (3)$$

式中，$\boldsymbol{I}$表示单位矩阵。

对$\overline{\boldsymbol{L}}$进行特征值分解：$\overline{\boldsymbol{L}}=\boldsymbol{U}\Lambda\boldsymbol{U}^{-1}$，其中$\boldsymbol{U}$为特征向量，$\Lambda$的对角元素为特征值。将传统傅里叶变换的基底$\boldsymbol{U}^{\mathrm{T}}$用替换，得到图上信号$y$的傅里叶变换$\boldsymbol{U}^{\mathrm{T}}y$以及逆变换$\boldsymbol{U}(\boldsymbol{U}^{\mathrm{T}}y)$。根据卷积定理，图上信号$f$和$g$的卷积形式为

$$f \bullet g=\boldsymbol{U}(\boldsymbol{U}^{\mathrm{T}}f \cdot \boldsymbol{U}^{\mathrm{T}}g)=\boldsymbol{U}g\theta\boldsymbol{U}^{\mathrm{T}} \quad (4)$$

式中，将$U^{\mathrm{T}}g$改写为$g\theta$，可以看成是以$\theta$为参数的卷积核，由此便得到了图卷积神经网络中的信息传递公式。

## 3 多源数据特征的提取

特征提取是机器学习流程中非常关键的一步，它可以从原始数据中提取出有用信息，为后续的分类、聚类等任务提供有力支持。电力系统运行时，产生的数据类型多样、特点各异，具体包括动态时序数据如多为正弦信号的故障录波、只含有高低电平的数字量信号等，以及静态

数据如保护定值数据等[12-14]。

根据不同的数据特点，需要采取相适应的数据特征提取方法：针对故障录波中获取的模拟量信号，采用全周波傅里叶计算或多层平稳小波分解等信号分析手段提取其数据特征；针对SOE信号或故障录波中存在的保护以及开关动作信息，经过数据提取后，存储到特征矩阵中；针对相对不易变动的定值数据，通过定值管理系统和保护装置获取。其中如SOE动作信息、系统定值等数据，为避免其因为维度太低而“淹没”在其他信号中，将非时序的定值数据进行升维后融合到特征矩阵中。

经过对多源数据的上述处理后，将生成的特征矩阵转化为一维的特征向量，最终形成了电网拓扑图中单节点的特征向量，特征提取流程示意图如图2所示。

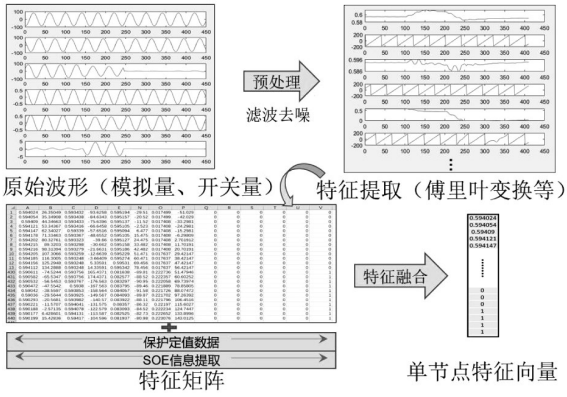



图2 电网数据特征提取与融合示意图

## 4 电网GCN模型结构

对图神经网络的研究中，图卷积神经网络（graph conventional network，GCN）的发展和应用最为广泛。和CNN类似，电网GCN结构包括输入层、图卷积层、池化层、全连接层和输出层[15]。图卷积层用来提取节点特征，卷积核通过在图中节点上进行移动来逐渐聚合邻居节点的信息，每多一层图卷积层，便能多聚合一阶子图的信息，不过卷积层数过多也会使得每个节点嵌入的特征相似，导致出现过平滑的问题，所以图卷积层的层数通常取值为2～3层。随着卷积层数的增加，CNN的感受域从1变成2×2，然后变为3×3；而GCN的感受域从初始中心节点变成一阶相邻节点，再变成二阶相邻节点，依此类推。

在图上应用CNN的第$k$层输出定义为

$$x_{k+1,j}=h\left(\sum_{i=1}^{f_{k-1}}\theta\widetilde{\mathrm{D}}^{-\frac{1}{2}}\widetilde{\boldsymbol{A}}\widetilde{\mathrm{D}}^{-\frac{1}{2}}x_{k,i}\right) \tag{5}$$

式中，$x_{k,i}$为第$k$层第$i$个节点的特征，$h$为非线性激活函数，$f_k$为更新后节点输出特征的维度，$\theta$为可学习参数，$\widetilde{\boldsymbol{A}}=\boldsymbol{A}+\mathrm{I}$，新的度矩阵对角元素$\widetilde{D}_{\mathrm{ii}}=\sum_{\mathrm{j}}\widetilde{\boldsymbol{A}}_{\mathrm{ij}}$。式(5)在输出聚集后特征的同时加入了一个可学习的卷积核，成功地将CNN的方法迁移到了图上。

## 5 算例分析

为验证本文所提出算法的有效性，在MATLAB中搭建一个由5条母线构成的电力网络，其结构图如图3所示。

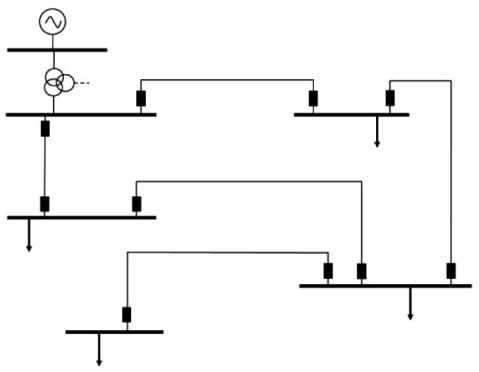


图3 仿真算例电网结构图

根据第二小节中的方法，将电力线路转化为图的节点后，生成的图模型中包含5个节点和6条边。在生成故障数据集时，分别模拟了故障在线路位置5%、50%、80%，故障过渡电阻为0.01 Ω、1 Ω、100 Ω、300 Ω和故障初始角度为0°、45°、90°、135°、180°的情形，另外假设每条线路分别故障和所有线路均正常，一共包含360种组合。利用蒙特卡洛方法对每种情形仿真时加入高斯白噪声运行10次，最终数据集包括3 600组数据，然后按照8:1:1的比例划分训练集、验证集和测试集。部分场景实验的故障定位结果准确率如表1。

表1 MDGNN模型故障定位准确率

| 故障位置/% | 故障电阻/Ω | 故障相角/° | 准确率/% |
|---|---|---|---|
| 50 | 0.01 | 0 | 99.0 |
| 50 | 300.00 | 0 | 96.5 |
| 50 | 0.01 | 90 | 98.2 |
| 50 | 0.01 | 135 | 98.6 |
| 5 | 0.01 | 0 | 97.7 |
| 80 | 0.01 | 0 | 97.5 |

从表1可以看出，MDGNN模型在电网故障区段定位上具有较高的准确率，并且几乎不受故障发生位置和故障初始相角大小的影响，仅在故障过渡电阻较大时定位准确率会略微下降。

本文还对比验证了MDGNN模型、仅考虑录波数据的GCN模型以及传统机器学习模型包括决策树和逻辑回归的故障区段定位准确性，其测试结果如图4所示。

从图4可以看出，本文提出的模型相比于其他模型具有更优良的表现。这主要是由于不同于以往的电网GCN

模型，本文提出的MDGNN模型融合了包括故障障录波数据在内的其他更为丰富的多源数据，从更多维度给故障诊断提供了判断信息。而传统机器学习模型如决策树和逻辑回归等只考虑了单个节点的分类属性，而并没有很好地考虑不同节点在拓扑结构上的连接关系。

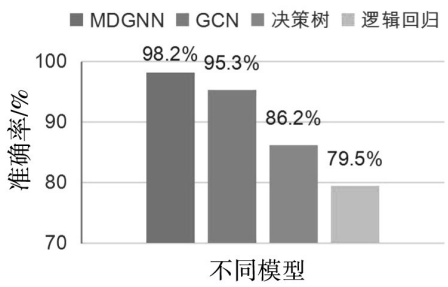



**图4 不同模型故障定位准确率对比**

## 6 结束语

随着现代化电力系统的不断发展和智能化程度的提高，故障诊断技术在保障电网运行安全和稳定方面扮演着越来越重要的角色。本文介绍了一种基于多源数据和图神经网络相结合的故障诊断模型，并将其应用于故障录波主站上。实验结果表明，该模型可以有效地实现对电力系统故障的快速准确诊断，为电力系统的安全运行提供有力的支持。本文所介绍的故障诊断模型在故障录波主站上的应用，为电力系统的安全稳定运行提供了新的思路和方法，也为未来故障诊断技术的发展奠定了基础。

**参考文献：**

[1] 袁春，张雪松. 电力故障录波数据综合处理系统功能分析[J]. 电力设备管理，2020(9)：64-66.

[2] 韩笑，郭剑波，蒲天骄，等. 电力人工智能技术理论基础与发展展望(一)：假设分析与应用范式[J]. 中国电机工程学报，2023，43(8)：2877-2891.

[3] 孙永辉，孟雲帆，葛磊蛟，等. 人工智能赋能微电网运行优化的应用及展望[J]. 高电压技术，2023，49(6)：2239-2252.

[4] 厉仄平，伍冲翀，熊来红，等. 基于机器学习和雷电感应电压的输电线路雷击定位方法[J]. 高压电器，2022，58(12)：109-116.

[5] 张宸滔，郑永康，卢继平，等. 基于图神经网络的智能变电站二次回路故障定位研究[J]. 电力系统保护与控制，2022，50(11)：81-90.

[6] 徐何军. 基于图神经网络的配电网故障诊断及重构优化研究[D]. 武汉：华中科技大学，2020.

[7] 刘玮，屠卿瑞，郭明宇，等. 基于差值有效值的智能录波器暂态同源比对算法研究[J]. 电力系统保护与控制，2021，49(16)：97-103.

[8] 吴奎忠，刘大鹏，崔运海，等. 基于两端故障数据同步和序量分解的线路参数在线量测[C]. 吉林：吉林省电机工程学会2022年学术年会，2022.

[9] 冷喜武，陈国平，蒋宇，等. 智能电网监控运行大数据分析系统的数据规范和数据处理[J]. 电力系统自动化，2018，42(19)：169-176.

[10] 周爱华，戴江鹏，丁杰，等. 面向多源异构电网数据的获取与转换技术研究[J]. 电力信息与通信技术，2015，13(7)：22-27.

[11] SCARSELLI F，GORI M，TSOI A C，et al. The graph neural network model[J]. IEEE transactions on neural networks，2008，20(1)：61-80.

[12] 阎博，张昊，郭子明，等. 基于多源数据融合的电网故障综合分析与智能告警技术研究与应用[J]. 中国电力，2018，51(2)：39-46.

[13] 王宇，高吉普，林呈辉，等. 基于多源数据融合的电网故障智能诊断方法研究[J]. 电子器件，2020，43(2)：304-308.

[14] 吴旭涛，马云龙，何宁辉，等. 基于多源数据融合的GIS机械故障检测技术[J]. 高压电器，2022，58(11)：191-196，204.

[15] 丁津津，邵庆祝，齐振兴，等. 基于迁移学习的卷积神经网络电网故障诊断[J]. 科学技术与工程，2022，22(14)：5653-5658.

作者简介：郑少明(1983—)，男，博士，高级工程师，研究方向：电力系统保护与控制。

通信作者：陈吉(1990—)，男，博士，中级工程师，研究方向：电力系统故障诊断与电力多源信号处理。