第 49 卷 第 6 期：2339-2347 高电压技术 Vol.49, No.6: 2339-2347
2023 年 6 月 30 日 High Voltage Engineering June 30, 2023
DOI: 10.13336/j.1003-6520.hve.20230195

基于消息传递网络的多变拓扑微电网群故障检测方法

郭 傲[1]，陈 颖[1]，肖谭南[1]，于智同[2]，宋炎侃[2]
（1. 清华大学电机工程与应用电子技术系，北京 100084;
2. 清华四川能源互联网研究院能源电力系统数字孪生研究所，成都 610042）

摘 要：随着分布式电源大量接入微电网群，微电网群故障检测面临传统就地检测方法难适应拓扑变化、多地信息检测数据质量和网络通讯要求高、数据驱动方法样本需求量大等问题。为此，提出了一种基于消息传递网络的故障检测方法，该方法将故障检测建模为微电网群节点的故障概率预测问题，建立从微电网群故障波形到各节点故障类型的映射。模型利用卷积神经网络对各节点故障波形进行特征提取，所得局部节点特征经消息传递网络在邻近节点之间传播，更新节点特征用于故障定位和故障类型识别。针对拓扑变化的复杂故障场景，设计根据微电网群运行状态变化的拓扑特征，构造增强样本数据集以抵抗数据丢失，减小总样本需求量。最后，在 CloudPSS 平台搭建了实际微电网群仿真算例，算例测试结果表明所提方法故障定位精度高，故障类型识别准，抗数据丢失能力强，样本需求量较低，且可以适应微电网群多变的运行状态和拓扑结构。
关键词：微电网群；故障检测；图神经网络；消息传递网络；拓扑泛化；数据增强

A Fault Detection Method for Multi-microgrid Considering Topological Variations Based on Message Passing Neural Network

GUO Ao[1], CHEN Ying[1], XIAO Tannan[1], YU Zhitong[2], SONG Yankan[2]
(1. Department of Electrical Engineering, Tsinghua University, Beijing 100084, China;
2. Institute of Energy and Power System Digital Twin, Sichuan Energy Internet Research Institute, Tsinghua University, Chengdu 610042, China)

Abstract: With the increase of distributed generators in multi-microgrid, multi-microgrids face a large number of problems in fault detection, for example, traditional in-place detection methods are difficult to adapt to topology changes, high data quality and network communication are required for multi-site detection methods, and samples of data-driven methods are massively needed. To solve these problems, a fault detection method based on message passing neural network (MPNN) is proposed, in which the fault detection is modeled as a fault probability prediction problem for multi-microgrid nodes, and a mapping from the multi-microgrid fault waveform is established to the fault type of each node. In the model, convolutional neural networks are adopted to extract features from each node fault waveform. The resulting local node features are propagated among neighboring nodes via an MPNN to update node features for fault localization and fault type classification. For complex fault scenarios with topology changes, topology features are designed to change with the operating state of the multi-microgrid. An enhanced sample dataset is constructed to resist data loss and reduce the total sample requirements. Finally, a multi-microgrid simulation model is built in CloudPSS. The test results show that the proposed method has high fault location accuracy, high fault type classification accuracy, strong resistance to data loss, low sample requirement, and can adapt to the changing operating state and topology of multi-microgrid.
Key words: multi-microgrid; fault detection; graph neural network; MPNN; topology generalization; data enhancement

0 引言

在“碳达峰与碳中和”战略的引导下，我国产业结构和能源结构调整持续推进，分布式电源大量接入[1]。微电网在分布式电源的有效利用和灵活控制方面被广泛应用。当多个微电网互相连接且互相之间存在配电线路时会形成微电网群[2-3]，微电网群在城市配电网末端、偏远地区具备广阔的应用前景。

目前，对微电网群的研究主要针对协同运营、分层控制方面[4-6]，对于故障检测的研究相对较少。微电网群的故障检测包含故障定位和故障类型识别

基金资助项目：国家自然科学基金(U22B2096；52211530051)。
Project supported by National Natural Science Foundation of China (U22B2096, 52211530051).

两个方面，是系统快速隔离故障和恢复的基础，也是微电网群的运行、控制和保护中非常重要的一环[7]。由于分布式电源的多点接入，微电网的故障潮流方向会发生异变，故障电流的大小受电子元件的限制也会大大下降[8]。微电网群由多个微电网互联互供组成，其运行状态相比普通微电网更为复杂，拓扑结构更加多变，使得微电网群的故障检测异常复杂，故障定位和识别十分困难。

一部分研究将传统保护引入微电网，基于就地信息进行故障检测。文献[9]结合传统差动电流和自适应方案，解决了通信成本和可靠性的问题，但是差动保护只在高优先级和高风险区使用，当通信受到干扰时灵敏度将无法保证，对量测数据质量要求较高。文献[10-11]利用行波信息定位故障线路，但会受到微电网拓扑变化的影响，不适用于孤岛运行和环形微电网。

考虑通信单元和通信平台，基于多地信息的故障检测方法在一定程度上可以解决由于微电网复杂运行状态带来的影响。文献[12]用图描述微网，以分割区域为节点，以断路器开关为边，基于微网图模型得到边方向变化量检测算法。文献[13]利用分层 Petri 网检测模型处理微电网故障信息，对拓扑结构变化有较强鲁棒性。这些基于多地信息的故障检测方法考虑了拓扑信息在故障检测中的作用，但会受到数据质量和网络通信的限制。

近年来，越来越多的研究采用数据驱动和人工智能的方法进行微电网故障检测。文献[14]利用离散傅里叶变换估计敏感特征计算出差分特征，用于建立基于决策树的数据挖掘模型，适用于不同的拓扑结构。文献[15]基于随机森林算法实现故障检测，解决了由于逆变器产生故障电流大小过小的问题，但是以上两种方法均不能判断故障类型。文献[16]以小波变化构建特征，再由深度神经网络推断故障类型、相位和位置信息，能适应并网和孤岛不同的运行状态，但是对训练集样本数量要求较高。

微电网群分布式电源多、拓扑变化多且连接线路较短。传统保护的故障检测方法忽略了其他节点的状态，难以适应拓扑变化的情况。基于多地信息的故障检测方法能适应变化的拓扑结构但对数据质量和网络通信的要求高。基于数据驱动的故障检测精度高，但在故障类型多、线路多、故障场景多的情况下，训练集样本量要求较高，且实际工程应用中，量测装置存在数据丢失的现象，进一步降低了此类方法的鲁棒性。

本文针对微电网群的故障检测问题，提出了一种基于消息传递网络(message passing neural network，MPNN)的检测算法[17]，将微电网群的故障检测建模为节点故障概率预测问题，采用局部节点状态推断和邻近节点相关性分析结合的方法，以较少训练样本获得故障检测模型。检测算法以卷积神经网络(convolutional neural networks，CNN)作为局部节点状态推断网络，通过 MPNN 整合邻近节点信息，更新节点预测状态。该方法充分考虑了微电网群的拓扑关系和节点信息的相关性，可以适应微电网群不同的运行状态以及拓扑结构，实现了少量训练样本下微电网群不同拓扑的准确定位和故障类型识别，并具备一定的抗数据丢失能力。本文依托 CloudPSS 仿真平台搭建了微电网群模型[18]，对所提模型进行了验证测试。

1 微电网群故障检测建模

1.1 微电网群拓扑

常见交流微电网群架构如图 1 所示，其中连接子微网的低压馈线上无分布式电源或者负载[19-21]。分布式电源和负荷均连接在子微网的公共连接点(point of common coupling，PCC)上。

微电网群包含多个互联互供的微电网，这就导致其拓扑更加多变。各子微网可以接入上级电网联网运行，也可以断开与上级电网的连接成孤岛运行，多个子微网也可互联构成离网微电网群。在一个微电网群中可能存在部分子微网并网运行，部分子微网孤岛运行。

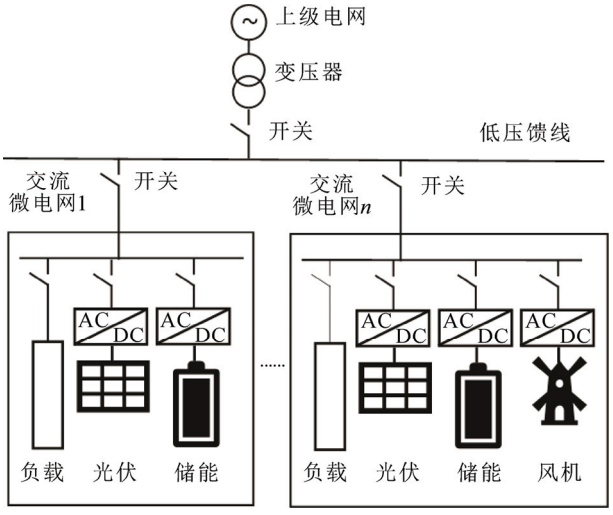


图 1 基于交流微电网的微电网群架构

Fig.1 Multi-microgrid architecture consisting of AC microgrids

1.2　微电网群故障检测问题建模

微电网群的故障检测需要根据元件的短时间时序量测数据来判断是否存在故障以及故障类型。这是一个基于元件运行状态的分类问题，但是由于量测数据可能存在数据丢失现象，这会对检测的准确性产生一定的影响。

同时微电网中分布式能源的短路容量相对较小，所以与大电网相比，微电网提供的短路故障电流能力很低，在微电网群系统并网运行时，故障电流比在孤岛运行时要大得多。而微电网群的拓扑结构比较复杂，子微网的并网和孤岛运行可能同时存在，仅依靠元件的短时间时序量测数据对微电网群的故障检测模型的要求过高。为了解决这个问题，在模型设计中加入了拓扑信息，建立了如式(1)所示的微电网群故障检测模型。

$$\boldsymbol{P}=f(\boldsymbol{X},\boldsymbol{A};\theta) \tag{1}$$

式中：$\boldsymbol{X}$ 为微电网群电气节点时序量测矩阵，量测矩阵中可能存在部分数据为空；$\boldsymbol{A}$ 为微电网群拓扑矩阵，随着微电网群拓扑改变而变化；f 为时序量测数据与拓扑矩阵到元件运行状态概率的非线性映射模型；θ 为模型参数；$\boldsymbol{P}$ 为元件运行异常概率矩阵。

2　用于微网群故障检测的 MPNN 设计

2.1　故障检测模型设计

本文结合就地信息故障检测与多地信息故障检测的思想，将微电网群故障检测问题的求解分解为 3 个步骤：局部节点特征提取；邻近节点特征融合与节点状态预测；故障线路和故障类型推断。

首先，类比就地信息故障检测，各电气节点基于本地时序量测数据对节点状态进行特征提取。电气节点时序量测 $\boldsymbol{X}$ 由近馈线侧线路电流构成，时序量测长度为 N_{T}。所有可量测节点的时序量测构成了微电网群电气节点 3 维量测矩阵 $\boldsymbol{X}\in\mathbf{R}^{N_{\mathrm{v}}\times 3\times N_{\mathrm{T}}}$，其中 N_{v} 为可量测电气节点数量。将各节点量测输入同一个 CNN 网络与多层感知机(multi-layer perceptron，MLP)，提取局部节点状态特征，如式(2)所示。

$$\boldsymbol{\mathcal{X}}=C(\boldsymbol{X};\theta_1) \tag{2}$$

式中：$\boldsymbol{\mathcal{X}}\in\mathbf{R}^{N_{\mathrm{v}}\times N_{\mathrm{h}}}$ 为电气节点状态特征矩阵；N_{h} 为提取特征的维数；C 为 CNN 与 MLP 构造的局部节点特征提取模型；θ_1 为该模型参数。

接着，类比故障影响的传播过程，局部节点状态特征沿着节点之间的线路传播，各节点融合邻近节点状态更新节点状态特征。根据微电网群实时运行状态，输入可变拓扑特征，设计基于消息传递机制的 MPNN，实现节点特征的传播与更新，并将更新后的节点特征输入 MLP，经激活函数后，输出节点运行状态的预测结果，如式(3)所示。

$$\boldsymbol{\mathcal{Y}}=S(\boldsymbol{\mathcal{X}},\boldsymbol{A};\theta_2) \tag{3}$$

式中：S 为构造的 MPNN 模型；θ_2为消息传递网络参数；$\boldsymbol{\mathcal{Y}}\in\mathbf{R}^{N_{\mathrm{v}}\times N_{\mathrm{m}}}$ 为电气节点状态概率矩阵；N_{m} 为节点预测状态总数。

所提微电网群故障定位 MPNN 的结构和运行机制与微电网群电气特性存在较强的耦合关系。尤其是通过消息传递，将拓扑变化的影响融入模型的学习之中，使模型学习了电气节点状态特征之间的依赖关系，适应微电网群复杂的运行状态。因此，经过多层消息传递后，MPNN 中节点状态特征输出向量可反映电气状态异常水平。将所有节点状态特征向量集成输入分类用全连接网络，可进一步输出节点异常概率矩阵 $\boldsymbol{P}$ 和故障类型标签矩阵 $\boldsymbol{Y}$。

$$(\boldsymbol{P},\boldsymbol{Y})=e(\boldsymbol{\mathcal{Y}}) \tag{4}$$

$$g(\boldsymbol{\mathcal{Y}},\boldsymbol{A})=g(\boldsymbol{P},U(\boldsymbol{Y},\boldsymbol{A})) \tag{5}$$

式中：节点标签矩阵 $\boldsymbol{Y}$ 为各节点经模型映射后输出概率最大的标签；e 为标签映射；U 为线路映射；定位推断逻辑函数 g 输出故障线路、区域以及故障类型。

通过有监督学习，基于带有标签的样本集合，可构建学习模型，将原本节点标签预测概率的优化过程转化为神经网络的参数优化问题，获得最优参数 θ_1和 θ_2，即：

$$\theta_1^*,\theta_2^*=\underset{\theta_1,\theta_2}{\operatorname{argmax}}\prod_k\mathcal{P}\left(\boldsymbol{Y}_k=\hat{\boldsymbol{Y}}_k\mid\boldsymbol{X}_k;\theta_1,\theta_2\right) \tag{6}$$

式中：θ_1^* 和 θ_2^* 分别是求解得到的最优参数；$\mathcal{P}$ 是概率预测模型；Y_k 和 $\hat{Y}_k$ 分别是样本 k 的预测标签和真实标签矩阵；X_k 为样本 k 的输入量测矩阵。根据故障定位的需求将式(6)转化形成损失函数，基于梯度下降的训练算法对参数 θ_1和 θ_2更新。对于多分类问题，一般选用交叉熵损失函数，其计算方式为式(7)。其中 L 表示模型输出与实际结果之间的距离；p_i 表示每一类标签的预测概率；y_i 表示标签，当样本属于对应标签类别时为 1 否则为 0。单条线路故障的情况下，只有两个节点为故障标签，导致故障标签数量与正常标签数量极端不平衡。数据不平衡会导致的模型学习故障特征困难，因此在损失函数中引入与标签数量负相关的权重 w_i 来提升模型对故障标签数据的学习效果，计算式如下。

$$L=-\sum_{i=1}^{n} w_i y_i \ln p_i \tag{7}$$

综上可见，本文所设计的故障定位 MPNN 网络是微电网群物理实体在神经网络模型空间的一种投影，有助于提升系统故障定位性能。

2.2 节点网络设计

节点网络是处理输入节点状态数据的前置局部信息提取网络，对输入数据进行初始特征提取，并需要对数据随机丢失等数据质量问题具备一定的鲁棒性。同时为了防止训练时参数量过大，节点网络结构应相对简单，分别使用了 CNN 以及 MLP 作为节点网络进行了测试。

输入为电气节点时序测量矩阵。输入数据如有数据丢失的情况，则丢失的部分矩阵元素设为 0。输出为电气节点异常状态特征向量，特征向量直接进入后续消息传递网络。

2.3 消息传递网络设计

MPNN 与 CNN 类似，通过循环聚合传递邻居节点的信息形成节点的特征向量，多层图卷积运算可以看作是在图上进行多次消息传播。本章构建的 MPNN 为全采样的 GraphSAGE(graph sample and aggregate)，一共 4 层网络，每一次网络消息传递的具体计算过程为

$$\begin{cases} h_{N(i)}^{(l+1)}=G\left(\left\{h_j^l,\forall j\in N(i)\right\}\right) \\ h_i^{(l+1)}=\sigma\left(W\cdot c(h_i^l,h_{N(i)}^{(l+1)})\right) \\ h_i^{(l+1)}=n(h_i^{(l+1)}) \end{cases} \tag{8}$$

式中：$h_{N(i)}^{(l+1)}$ 是节点 i 所有邻居节点第 l–1 次卷积生成的特征的聚合特征；$h_i^{(l+1)}$ 为第 l 次卷积后节点 i 的节点特征；$N(i)$为节点 i 的邻居节点构成的集合；σ 为非线性变化函数；W 为权重；c 表示拼接；n 表示 L2 范数归一化；G 是消息聚合方式。本文采用池化聚合的方式进行节点的消息聚合，如式(9)所示。

$$G^{(l)}=m\left(\left\{\sigma\left(Wh_j^l+b\right),\forall j\in N(i)\right\}\right) \tag{9}$$

式中：m 表示取每个特征的最大值；b 是偏置参数。这种聚合方式下，所有的邻居节点先进行一次非线性变化，经过一个 MLP 提取特征，然后做最大值池化形成节点的特征信息。

若加入节点之间的每条边的权重之后，聚合过程变为式(10)。

$$h_{N(i)}^{(l+1)}=G\left(\left\{e_{ji}h_j^l,\forall j\in N(i)\right\}\right) \tag{10}$$

式中：e_{ji} 表示节点 j 到节点 i 之间边的权重。拓扑特征的输入界定了每一个节点的邻居节点，例如邻接矩阵表示顶点之间相邻关系，输入邻接矩阵进 MPNN 即可获取所有 $N(i)$。

由计算过程可知，在每一次消息传播循环中，首先将节点 i 所有邻居节点的第 l–1 次节点特征聚合产生节点 i 的聚合特征，然后将其和节点 i 的 l–1 次节点特征进行拼接，再经过非线性变化后生成节点 i 的 l 次节点特征，最后对其进行 L2 范数归一化得到新的节点特征。

消息传递网络模型整体架构设计如图 2 所示。

3 拓扑泛化和抗数据丢失设计

3.1 拓扑特征设计

为适应微电网群多变的运行状态和拓扑结构，设计专用于 MPNN 的拓扑特征。电力网络天然拥有图结构，可将微电网群各个电力节点以及线路抽象为节点与边构成的图。图 3 是一个简单的微电网群拓扑图结构，其中 0 号节点为母线，4 号节点为储能，5 号节点和 7 号节点为光伏，节点 2、5、6 和节点 3、7、8 分别组成两个子微网。

图的拓扑特征需要表达电力系统节点之间的电气连接关系，刻画电气联系的强弱，从而影响信息特征在图上的传递。微电网群中线路长度较短，线路阻抗影响较小，节点导纳矩阵或者节点阻抗矩

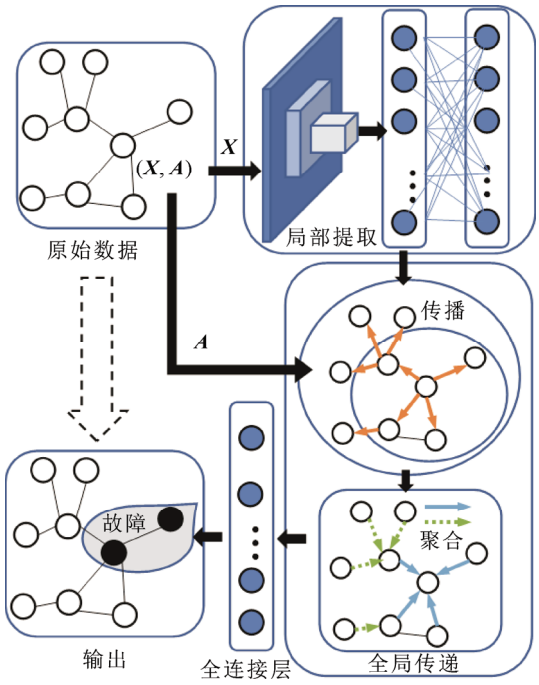


图 2 消息传递网络模型示意图

Fig.2 Schematic diagram of MPNN model

阵可以作为拓扑特征，但会使图卷积的计算复杂度过大，因此采用邻接矩阵作为图的拓扑特征。

MPNN 中特征传递的方向由拓扑特征决定。微电网群中电气节点之间能量传递的方向并不都是双向，使用无向图邻接矩阵作为拓扑特征会丢失电力系统中潮流的方向信息，因此从能量流向的角度对其进行优化。图 3 所示的简单微电网群中，当光伏节点的出力较小时，能量从 0 节点单向流向 1 节点，节点 5 和 7 也是光伏单向输出能量，节点 4 和 1 之间的能量流动方向则由储能充放电的状态决定。当储能充电，微电网群并网运行时，其邻接矩阵 $\boldsymbol{A}$ 以及改进后的邻接矩阵 $\boldsymbol{A}'$ 如下所示：

$$\boldsymbol{A}=\begin{bmatrix}0&1&0&0&0&0&0&0&0\\1&0&1&1&1&0&0&0&0\\0&1&0&0&0&1&1&0&0\\0&1&0&0&0&0&0&1&1\\0&1&0&0&0&0&0&0&0\\0&0&1&0&0&0&0&0&0\\0&0&1&0&0&0&0&0&0\\0&0&0&1&0&0&0&0&0\\0&0&0&1&0&0&0&0&0\end{bmatrix},\ \boldsymbol{A}'=\begin{bmatrix}0&1&0&0&0&0&0&0&0\\0&0&1&1&1&0&0&0&0\\0&1&0&0&0&0&1&0&0\\0&1&0&0&0&0&0&0&1\\0&0&0&0&0&0&0&0&0\\0&0&1&0&0&0&0&0&0\\0&0&0&0&0&0&0&0&0\\0&0&0&1&0&0&0&0&0\\0&0&0&0&0&0&0&0&0\end{bmatrix}\tag{11}$$

当微电网群离网，子微网分别孤岛运行时，储能放电，3 号节点和 1 号节点断开，图 3 所示微电网群其邻接矩阵 $\boldsymbol{A}$ 以及改进后的邻接矩阵 $\boldsymbol{A}'$ 如下所示：

$$\boldsymbol{A}=\begin{bmatrix}0&0&0&0&0&0&0&0&0\\0&0&1&0&1&0&0&0&0\\0&1&0&0&0&1&1&0&0\\0&0&0&0&0&0&0&1&1\\0&1&0&0&0&0&0&0&0\\0&0&1&0&0&0&0&0&0\\0&0&1&0&0&0&0&0&0\\0&0&0&1&0&0&0&0&0\\0&0&0&1&0&0&0&0&0\end{bmatrix},\ \boldsymbol{A}'=\begin{bmatrix}0&0&0&0&0&0&0&0&0\\0&0&1&0&0&0&0&0&0\\0&1&0&0&0&0&1&0&0\\0&0&0&0&0&0&0&0&1\\0&1&0&0&0&0&0&0&0\\0&0&1&0&0&0&0&0&0\\0&0&0&0&0&0&0&0&0\\0&0&0&1&0&0&0&0&0\\0&0&0&0&0&0&0&0&0\end{bmatrix}\tag{12}$$

当微电网群拓扑结构改变、运行方式变化时，按照本节所提拓扑特征设计方法改变模型的拓扑特征输入即可。

3.2　故障样本生成和抗数据丢失

本文构建微电网群仿真模型，采用 CloudPSS 平台开展电磁暂态仿真产生故障样本数据。每次线路故障时，模拟故障录波器的动作，若线路过电流幅值超过正常时 1.2 倍，则保留触发后一个周波内的三相电流波形数据。获取到的线路时序量测构成电气节点量测矩阵 $\boldsymbol{X}$，生成故障数据样本集。故障类型包含单相接地短路，双相接地短路，两相短路和三相短路，如表 1 所示。针对微电网群中每条线路，随机模拟 10 种故障，批量仿真生成故障数据集。

为提升网络抗数据丢失能力，设计 CNN 为节点网络。CNN 参数量小，其二维卷积特性天然对数据随机丢失等数据质量问题具备一定的鲁棒性，为了保证节点网络的特征提取能力，卷积核模块采用多卷积核并行合并的 GoogleNet[19]，节点网络中叠加两层卷积网络。

进一步，在原始数据集的基础上构建增强数据集。原始数据集中量测矩阵是各个节点的三相电流波形，将完整的电流波形数据随机丢失部分数据点产生残缺波形数据。分别将两份原始数据集中每一条电流波形均随机丢失 20%和 50%，形成两个残缺波形数据集，将两个残缺波形数据集与原始数据集合并，形成样本数量为原始数据集三倍的增强数据集。

最后，原始数据集和增强数据集均按照 4:1 的比例划分训练集和测试集。同时，在原始数据测试集上以 10%~60%的比例构成残缺波形数据测试集，用于测试所提方法抗数据丢失能力。

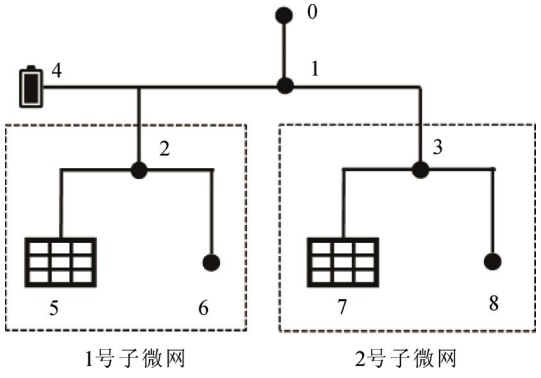


图 3　简单微电网群拓扑图结构

Fig.3　Simplified topology diagram of a multi-microgrid

表 1　故障类型

Table 1　Fault type

故障类型	相序
单相接地短路	(A/B/C)G
双相接地短路	AB,AC,BC
两相短路	(AB/AC/BC)G
三相短路	ABCG
总和	10

4 算例分析

4.1 算例设计

本文在 CloudPSS 中搭建了图 4 所示的交流微电网群电磁暂态仿真模型。

按照第 3 章所提故障样本生成方法和增强数据集生成方法，生成 3000 个故障样本，并构造增强数据集，交流微电网群电磁暂态仿真算例参数如表 2 所示。

考虑在微电网群建模中储能电池与母线是直连，并无线路信息，在样本生成中储能电池与母线之间并未设置故障。

4.2 模型故障检测能力分析

使用原始数据集对模型进行训练和测试，测试结果以故障子微网定位准确率，故障线路定位准确率、故障类型识别准确率作为评价指标。为了验证节点网络和 MPNN 组合的性能优越性，分别使用 CNN 模型、CNN 作为节点网络的 MPNN 模型(CNN-MPNN)、MLP 模型，MLP 作为节点网络的 MPNN 模型(MLP-MPNN)这 4 种模型进行测试。其中，CNN 和 MLP 模型直接将节点网络的输出作为故障定位逻辑函数的输入进行故障检测。4 种模型的测试结果如表 3 所示。

从表 3 可以看出，单独使用 CNN 模型和 MLP 模型性能均一般，加入 MPNN 后故障检测性能明显提升。故障线路定位准确率以及故障区域定位准确率均超过 99%，定位故障线路并识别故障类型的准确率均超过 95%。CNN-MPNN 故障类型识别准确率略微低于 MLP-MPNN，故障线路定位准确率略高，但其模型参数大小远小于 MLP-MPNN，训练代价更小。以上结果说明基于节点局部特征的神经网络在微电网群故障定位中性能有限，考虑拓扑相关性后网络定位和识别的性能大幅提升。

4.3 模型抗数据丢失能力分析

考虑实际电网中存在量测数据丢失问题，使用 3 个对比模型以及本文所用模型分别进行测试，测试结果如图 5 所示。

其中本文模型是 CNN-MPNN 并由增强数据集训练，对比模型 1 是 MLP-MPNN，对比模型 2 是 CNN-MPNN 由原始数据集训练，对比模型 3 是 MLP-MPNN 并由原始数据集训练。故障诊断准确率是准确定位故障线路同时故障类型识别正确的准确率。

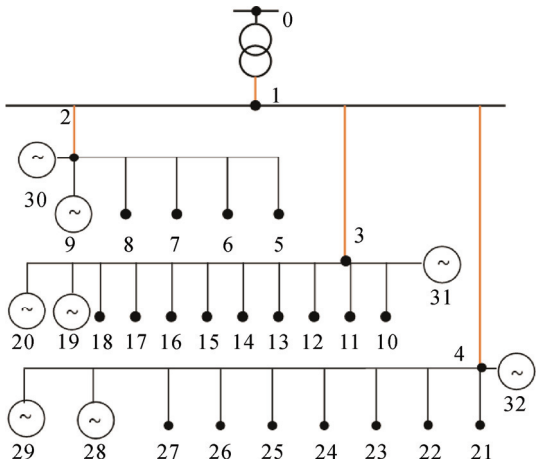


图 4 微电网群拓扑

Fig.4 Multi-microgrid topology

表 2 微电网群仿真参数

Table 2 Multi-microgrid simulation parameters

节点属性	节点编号	节点状态
母线	0	10 kV 母线
微电网并网口	1、2、3、4	—
储能	30、31、32	并网充电，离网放电
光伏	9、19、20、28、29	0.7~1 倍波动
负荷	5~9、10~18、21~27	0.5~1.2 倍波动

表 3 4 种模型的测试结果

Table 3 Test results of four models

模型	故障子微网定位准确率/%	故障线路定位准确率/%	故障类型识别准确率/%
CNN	88.23	83.41	78.38
CNN-MPNN	99.83	99.83	95.17
MLP	92.83	89.33	86.50
MLP-MPNN	99.83	99.67	96.33

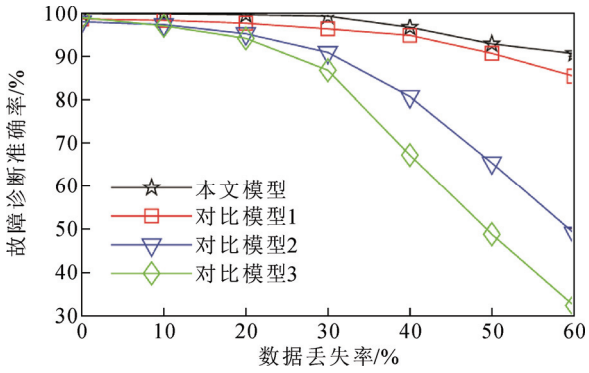


图 5 不同对比模型测试结果

Fig.5 Test results of different comparison models

由图 5 可见，随着数据丢失率的增大，对比模型 2 和对比故障 3 定位准确率下降幅度很大。而本

文模型以及对比模型 1 是鲁棒的模型，其中本文模型性能更好，面对不同比例的数据丢失，均表现出良好的性能。说明以 CNN 作为节点网络，通过在原始数据集中引入固定比例波形数据丢失构造增强数据集的方式，在不新增数据采样的前提下，可以显著提高模型的鲁棒性。

4.4　拓扑变化下模型效果分析

微电网群在不同运行状态下，其拓扑结构也会发生改变，本文构建了 4 种典型的运行状态，其拓扑类型以及节点变化如表 4 所示。

改变微电网群的节点连接，4 种运行状态对应的拓扑如图 6 所示。

按照第 3 章所提拓扑特征设计方法和样本生成方法，改变不同运行状态下输入网络模型的拓扑特征，并重新生成样本集合。样本合集的数量分类和测试结果如表 5 和表 6 所示。

所有模型计算均在在一台配备 AMD Ryzen 9 5900HX CPU 和 NVIDIA GeForce RTX 3060 Laptop GPU 的电脑上完成。拓扑变化下本文模型训练耗时 728.9 s，调用模型单次故障诊断耗时 1.8 s。

从以上测试结果可以看出，当微电网群运行状态改变，存在不同的拓扑结构时，单独的节点网络故障检测能力大幅下降，而输入改进拓扑特征的 MPNN 模型依然可以保持 99%以上的故障线路定位能力和 98%以上的故障类型识别能力。本文所提的 MPNN 模型可以适应微电网群复杂的运行状态，对拓扑变化具备很强的鲁棒性。

同时考虑数据丢失和拓扑变化，用增强数据集训练本文模型，拓扑变化数据集的数据丢失测试结果如表 7 所示。

从表 7 可以看出，抗数据丢失设计在拓扑变化的情况下仍可以使训练出来的网络是鲁棒的模型，故障线路定位准确率一直保持在 99%以上，故障类型识别准确率随着数据丢失率的增大缓慢下降，保持优秀的故障诊断能力。

表 4　拓扑变化仿真参数

Table 4　Topology change simulation parameters

拓扑类型	节点变化	微网群状态
1	—	并网运行
2	节点 0、1 断开	微电网群离网运行
3	节点 1、3 断开	2 号子微网离网，其他两个子微网并网运行
4	节点 0、1 断开，节点 1、4 断开	微电网群离网运行，1、2 号子微网联网

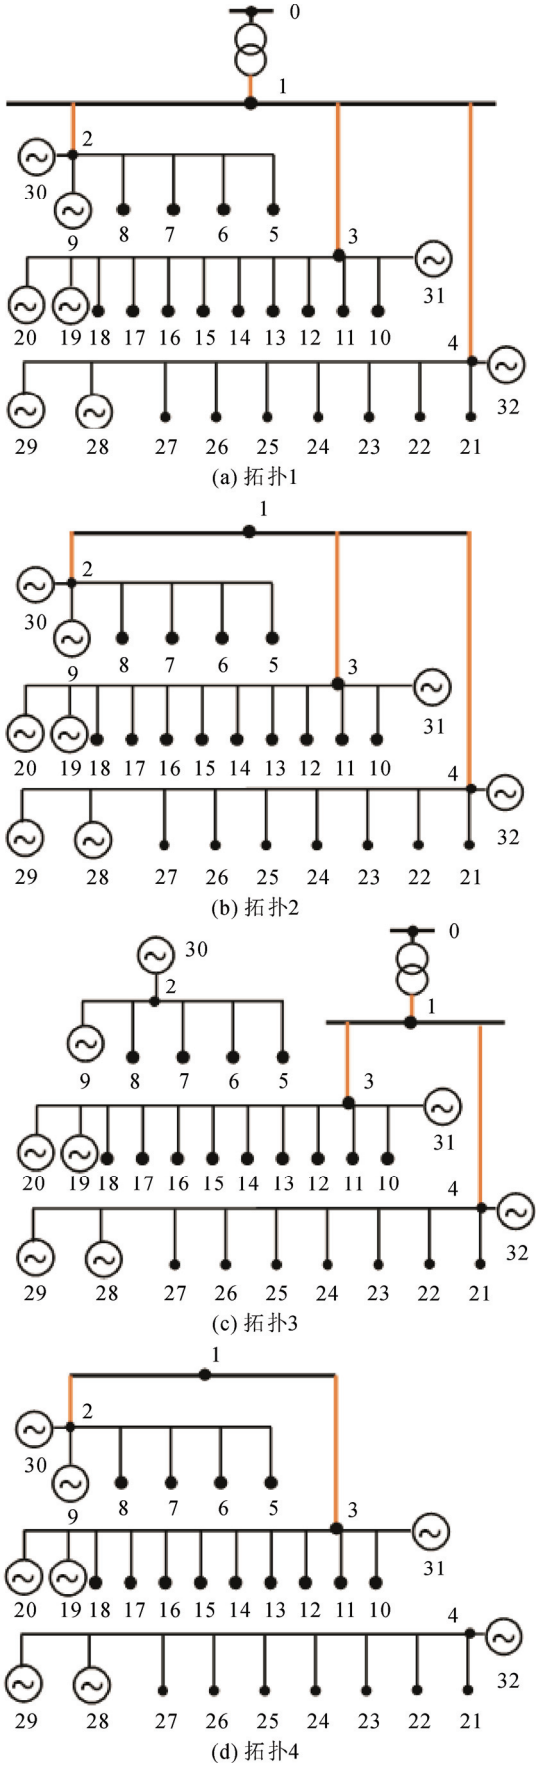


图 6　4 种运行状态拓扑

Fig.6　Topology of four operating states

表 5 样本集合数量

Table 5 Sample set size

样本集合	总数	训练集	测试集
拓扑类型 1 数据集	3000	2400	600
拓扑类型 2 数据集	2890	2312	578
拓扑类型 3 数据集	2911	2329	582
拓扑类型 4 数据集	2776	2221	555
总和	11 577	9262	2315

表 6 拓扑变化下 4 种模型的测试结果

Table 6 Test results of four models under topology changes

模型	故障子微网定位准确率/%	故障线路定位准确率/%	故障类型识别准确率/%
CNN	65.33	62.49	47.86
CNN-MPNN	99.95	99.90	98.16
MLP	77.41	76.02	75.83
MLP-MPNN	99.90	99.86	96.73

表 7 拓扑变化下数据丢失的测试结果

Table 7 Test results of fault detection with topology change and data loss

数据丢失率/%	故障子微网定位准确率/%	故障线路定位准确率/%	故障类型识别准确率/%
0	100.00	100.00	99.76
10	100.00	100.00	98.61
20	100.00	99.95	98.56
30	99.86	99.76	95.43
40	99.76	99.66	93.16
50	99.47	99.04	90.18
60	99.61	99.18	87.87

5 结论

1）以局部节点故障推断加上全局节点相关性分析的思路构建了一个故障检测算法模型，并设计以能量流向为基础的拓扑特征，使模型可以学习不同拓扑下的特征传递方式，在不同的运行状态下均可以精确故障定位和故障类型识别。

2）采用 CNN 作为节点网络，并设计了增强数据集的构造方法，使用少量故障数据即可训练出具备抗数据丢生能力的故障检测网络。

3）文中提出的基于消息传递网络的故障检测方法可以精确定位短路故障线路并识别短路故障类型，具备一定的适应拓扑连接变化以及抵抗量测数据丢失的能力，鲁棒性较强。

4）当前工作暂时没有考虑负荷发生变化的场景，在今后的工作中，一方面针对不同负荷类型在节点网络中加入针对负荷类型的网络，另一方面进一步拓宽故障检测适应范围，改进故障特征提取模型，提升消息传递网络的信息特征可解释性。

参考文献 References

[1] 袁志昌，郭佩乾，刘国伟，等. 新能源经柔性直流接入电网的控制与保护综述[J]. 高电压技术，2020，46(5)：1473-1488.
YUAN Zhichang, GUO Peiqian, LIU Guowei, et al. Review on control and protection for renewable energy integration through VSC-HVDC[J]. High Voltage Engineering, 2020, 46(5): 1473-1488.

[2] GIL N J, LOPES J A P. Hierarchical frequency control scheme for islanded multi-microgrids operation[C]// 2007 IEEE Lausanne Power Tech. Lausanne, Switzerland: IEEE, 2007: 473-478.

[3] NG E J, EL-SHATSHAT R A. Multi-microgrid control systems (MMCS)[C]// IEEE PES General Meeting. Minneapolis, USA: IEEE, 2010: 1-6.

[4] 赵 敏，陈 颖，沈 沉，等. 微电网群特征分析及示范工程设计[J]. 电网技术，2015，39(6)：1469-1476.
ZHAO Min, CHEN Ying, SHEN Chen, et al. Characteristic analysis of multi-microgrids and a pilot project design[J]. Power System Technology, 2015, 39(6): 1469-1476.

[5] 郭玲娟，魏 斌，韩肖清，等. 基于集合经验模态分解的交直流混合微电网混合储能容量优化配置[J]. 高电压技术，2020，46(2)：527-537.
GUO Lingjuan, WEI Bin, HAN Xiaoqing, et al. Capacity optimal configuration of hybrid energy storage in hybrid AC/DC micro-grid based on ensemble empirical mode decomposition[J]. High Voltage Engineering, 2020, 46(2): 527-537.

[6] 杨清志，蒋 伟，许春雷. 基于多智能体的交直流混合微电网监控设计与分层控制研究[J]. 高电压技术，2020，46(7)：2327-2339.
YANG Qingzhi, JIANG Wei, XU Chunlei. Monitoring design and research on hierarchical control of AC/DC hybrid microgrid based on multi-agent[J]. High Voltage Engineering, 2020, 46(7): 2327-2339.

[7] 年 珩，孔 亮. 直流微电网故障保护技术研究综述[J]. 高电压技术，2020，46(7)：2241-2254.
NIAN Heng, KONG Liang. Review on fault protection technologies of DC microgrid[J]. High Voltage Engineering, 2020, 46(7): 2241-2254.

[8] 薛士敏，李 蒸，刘存甲，等. 直流微网接地综述与基于控保协同的保护方法研究初探[J]. 高电压技术，2020，46(7)：2255-2268.
XUE Shimin, LI Zheng, LIU Cunjia, et al. Review of DC microgrids grounding and study on protection methods based on control and protection cooperation[J]. High Voltage Engineering, 2020, 46(7): 2255-2268.

[9] USTUN T S, KHAN R H. Multiterminal hybrid protection of microgrids over wireless communications network[J]. IEEE Transactions on Smart Grid, 2015, 6(5): 2493-2500.

[10] SHI S X, JIANG B, DONG X Z, et al. Protection of microgrid[C]// 10th IET International Conference on Developments in Power System Protection (DPSP 2010). Managing the Change. Manchester, England: IET, 2010: 1-4.

[11] BORGHETTI A, BOSETTI M, NUCCI C A, et al. Integrated use of time-frequency wavelet decompositions for fault location in distribution networks: theory and experimental validation[J]. IEEE Transactions on Power Delivery, 2010, 25(4): 3139-3146.

[12] 吴在军，赵上林，胡敏强，等. 交流微网边方向变化量保护[J]. 中国电机工程学报，2012，32(25)：158-166.
WU Zaijun, ZHAO Shanglin, HU Minqiang, et al. Branch directional variation protection of AC microgrid[J]. Proceedings of the CSEE,

2012, 32(25): 158-166.

[13] 刘科学，宣文华，魏少鹏，等. 一种基于高级 Petri 网的微电网故障诊断方法[J]. 电力系统保护与控制，2016，44(15)：106-111.
LIU Kexue, XUAN Wenhua, WEI Shaopeng, et al. A method of micro grid fault diagnosis based on high-level Petri net[J]. Power System Protection and Control, 2016, 44(15): 106-111.

[14] KAR S, SAMANTARAY S R, ZADEH M D. Data-mining model based intelligent differential microgrid protection scheme[J]. IEEE Systems Journal, 2017, 11(2): 1161-1169.

[15] CASAGRANDE E, WOON W L, ZEINELDIN H H, et al. A differential sequence component protection scheme for microgrids with inverter-based distributed generators[J]. IEEE Transactions on Smart Grid, 2014, 5(1): 29-37.

[16] YU J J Q, HOU Y H, LAM A Y S, et al. Intelligent fault detection scheme for microgrids with wavelet-based deep neural networks[J]. IEEE Transactions on Smart Grid, 2019, 10(2): 1694-1703.

[17] WU Z H, PAN S R, CHEN F W, et al. A comprehensive survey on graph neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(1): 4-24.

[18] 沈　沉，陈　颖，黄少伟，等. 新型电力系统仿真应用软件设计理念与发展路径[J]. 电力系统自动化，2022，46(10)：75-86.
SHEN Chen, CHEN Ying, HUANG Shaowei, et al. Design idea and development path of simulation application software for new power system[J]. Automation of Electric Power Systems, 2022, 46(10): 75-86.

[19] 周小平. 微电网功率协调控制关键技术研究[D]. 长沙：湖南大学，2018.
ZHOU Xiaoping. Research on the key technology of power coordination control in microgrid[D]. Changsha, China: Hunan University, 2018.

[20] 邢小文. 并网运行模式下微电网群分布式协调控制策略研究[D]. 西安：西北工业大学，2019.
XING Xiaowen. Research on distributed coordination control strategy for microgrids community in grid-connected operation mode[D]. Xi'an, China: Northwestern Polytechnical University, 2019.

[21] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, USA: IEEE, 2015: 1-9.



郭　傲
1998—，男，硕士生
主要从事人工智能和微电网智能运维方面的研究工作
E-mail: ga20@mails.tinghua.edu.cn

GUO Ao



陈　颖(通信作者)
1979—，男，博士，研究员，博导
主要从事并行计算与分布式计算、电磁暂态仿真、信息物理系统建模、信息物理安全方面的研究工作
E-mail: chen_ying@mail.tinghua.edu.cn

CHEN Ying
Ph.D., Professor
Corresponding author



肖谭南
1991—，男，博士(后)
主要从事电力系统稳定分析与控制、高性能计算与人工智能方面的研究工作
E-mail: ee_xiaoxh@foxmail.com

XIAO Tannan
Post-doctorate

收稿日期　2023-02-17　修回日期　2023-05-24　　编辑　曹昭君