

DOI:10.19651/j.cnki.emt.2212079

基于图注意力网络的输电线路故障诊断^{*}

唐 阔 高彦杰 汪长虹

(上海电力大学电子与信息工程学院 上海 200090)

摘要:以往基于深度学习的输电线路故障诊断,依赖数字信号处理技术提取故障特征。为了改进前述方法,引入了图深度学习理论,提出了一种基于图注意力网络(GAT)的智能故障诊断方法。将原始三相电流电压信号转化为图数据,利用多个图注意力层自动提取特征信息,从而建立了数据从输入端到输出端之间的映射关系,实现输电线路端到端的故障诊断。在400 kV三相输电线路和IEEE13总线电网系统上验证该方法的准确性和有效性,分别对五种短路故障和无故障情况设置不同初始相角、过渡电阻和故障位置进行仿真分析。结果表明,该方法故障诊断准确率达到99.75%以上,与现有几种智能故障诊断算法对比其性能最优。同时,该方法在不同白噪声下依然保持较高的故障识别率,具有良好的鲁棒性和泛化能力,为电力输电线路诊断技术提供了一定的研究思路。

关键词:故障诊断;图注意力网络;输电线路;深度学习

中图分类号: TM726 文献标识码: A 国家标准学科分类代码: 470.40

Fault diagnosis in transmission line based on graph attention network

Tang Min Gao Yanjie Wang Changhong

(School of Electronics & Information Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: The previous deep learning fault diagnosis methods for transmission lines rely on digital signal processing technology to extract fault features. In order to improve the above methods, this paper introduces graph deep learning theory and proposes an end-to-end intelligent fault diagnosis method based on graph attention network. The original three-phase current and voltage signals are converted into graph data, and the feature is automatically extracted using multiple graph attention layers, thus establishing the mapping relationship between the data from input to output, and realizing end-to-end fault diagnosis of transmission lines. The accuracy and effectiveness of the method are verified on the 400 kV three-phase transmission line and the IEEE13 bus power grid system, and the simulation analysis is carried out for five kinds of short circuit fault and no fault conditions with different initial phase angle, transition resistance and fault location. The results show that the fault diagnosis accuracy of this method is more than 99.75%, and its performance is the best compared with several existing intelligent fault diagnosis algorithms. At the same time, the method still maintains high fault identification rate under different white noise, has good robustness and generalization ability, and provides a certain research idea for power transmission line diagnosis technology.

Keywords: fault classification; graph attention network; transmission line; deep learning

0 引言

电力输电线路担负着输、配、送电的重要职能,其正常运作是电力系统安全稳定运行的有力保障。高压架空输电线路通常暴露于环境恶劣,地形复杂的地区,发生短路故障的客观因素较多,如高温雷雨天气、鸟类的误触、树木的倒塌等,因此,对故障线路进行快速、准确的诊断以提高电力系统供电可靠性或避免故障进一步扩散有重要意义。

近年来,关于输电线路故障诊断的方法,国内外学者都进行相关研究,主要分为基于模型和基于数字驱动^[1-2]两类方法。其中,基于数据驱动的方法无需考虑精确的电力系统数学模型,仅需比较完备的数据集,随着现代信息技术的高速发展,现已被广泛应用于故障诊断。现阶段随着人工智能技术发展,机器学习被应用于电力系统领域并成为数据驱动下输电线路智能故障诊断的主流方法之一,主要分为4个步骤:信号采集、数据预处理、特征提取、故障分类。

收稿日期:2022-11-14

*基金项目:国家自然科学基金(61401269)项目资助

实际工程中电力系统采集的原始信号是非平稳、非线性且含有大量噪声的,因此常使用数字信号处理方法^[3-5]对原始信号进行特征提取得到故障信息。常用的特征提取方法如,离散傅里叶变换(discrete fourier transform, DFT)、离散小波变换(discrete wavelet transform, DWT)^[6]、S 变换^[7]等。然后将得到的特征信息通过各种分类器以实现故障分类,常见的分类器如支持向量机(support vector machine, SVM)^[8-9]、决策树(decision tree, DT)^[10]、人工神经网络(artificial neural network, ANN)^[11]等。文献[12]利用信息熵理论提取特征信息后,结合随机森林算法对输电线故障进行分类。文献[13-14]通过小波理论进行故障特征信息提取,再将提取的特征输入到神经网络以实现故障诊断。上述方案依赖人工特征经验,分类的准确率很大程度取决于特征提取的优劣,且分类器和特征提取的组合算法计算效率较低。

随着各电力电子设备和分布式电源等接入,电力系统复杂多源,深度学习因其特征提取能力崭露头角。文献[15]以电网系统的总线电流电压序列作为输入,通过循环神经网络(recurrent neural network, RNN)对输入进行序列学习实现故障检测。文献[16]将原始电流电压转换成时序图像后,再利用自注意力卷积网络(self attention convolutional neural network, SAT-CNN)自动地提取图像特征进行故障分类。上述文献未同时考虑故障信号的序列特性和输电线路拓扑结构特性,在复杂的电力系统中通用性差。

图数据存在于社交网络、化学分子、交通网络等多方面,图神经网络(graph neural network, GNN)将传统的数据形式推广到图域,能够基于图数据自动化地进行高效学习,实现图数据与深度学习的结合。图卷积神经网络(graph convolution network, GCN)^[17-18]与图注意力网络(graph attention network, GAT)^[19]是两种应用广泛的 GNN 技术。GCN 从谱域的角度分析依赖拉普拉斯矩阵特定特征函数,对于电力系统而言适配性差,而 GAT 是一种基于空间的图卷积网络,能够更直观地得到电力输电线的拓扑信息。与普通神经网络相比,GAT 的图注意力层(graph attention layer, GAL)具有局部参数共享、感受野正比于网络层数卷积通性,且引入了注意力机制,实现了节点权重的自适应分配,能更好地提取故障局部信息的特征,文献[20]将 GAT 模型应用于电力系统的暂态稳定性评估中取得不错的效果,证明其优异的特征学习能力,具有广阔的应用前景。基于此,本文将 GAT 模型引入到输电线路系统中,提出一种新的智能故障诊断研究思路。

综合上分析,本文引入图深度学习方法,跳过人工特征选择过程基于 GAT 建立了一种适用于输电线路拓扑结构的故障诊断模型。以原始三相电流电压的暂态信息作为输入,考虑将标准化后的电压电流序列构建为无向图,利用 GAT 自动地提取图的特征信息,实现端到端的智能故障诊

断。通过仿真案例,测试多种工况下该模型的故障诊断准确性及验证高斯白噪声下模型的鲁棒性,同时将该方法与其他智能诊断算法作对比,实验结果表明,本文算法可以有效地实现输电线路故障诊断。

1 基于 GAT 的故障诊断模型

1.1 基于 GAT 的故障诊断网络结构

本文提出的故障诊断 GAT 网络结构如图 1 所示,由输入层、图注意力层、读出层、全连接层、输出层构成。输入层用于将采样的三相电流电压数据构建为图,图注意力层用于从图中提取特征信息进行训练,读出层聚合节点特征向量得到整图的特征表示,全连接层用于图分类任务,对最终得到的特征信息进行故障分类。

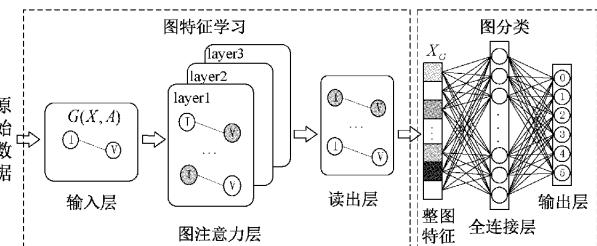


图 1 本文提出的基于 GAT 故障诊断网络结构

1) 输入层: 通过归一化处理和图构建两个过程,得到 GAT 模型的输入图 $\{G_1, G_2, \dots, G_k\} \subseteq \mathcal{G}$ 及对应的故障标签 $\{y_1, y_2, \dots, y_k\} \subseteq y$, 其中 {0, 1, 2, 3, 4, 5} 6 种分类标签分别表示无故障(NF)、单相短路接地(LG)、两相短路(LL)、两相接地短路(LLG)、三相短路(LLL)、三相接地短路(LLLG)6 种情况。

(1) 数据标准化处理: 数据集各样本具有不同的量纲且量级相差大,若直接使用原始数据作为输入,则网络训练收敛慢且不利于网络层之间的特征计算,使用如下标准化公式:

$$x^* = \frac{(x - \mu)}{\sigma} \quad (1)$$

式中: x 为原始数据, x^* 为标准化后的数据, μ 为原始数据集的均值, σ 为原始数据集的标准差。

(2) 图构建: 如图 2 所示,将系统的电气节点和架空线映射为图数据 $\mathbf{G}(\mathbf{X}, \mathbf{A})$, 即将标准化后故障后 64 ms(采样 64 个数据, 故序列长度为 64) 的电流电压序列值构成图数据。

其中, $\text{edge}=1$, 节点数 $N=2$ 表示电流电压两种值属性, 邻接矩阵 $\mathbf{A} = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \in \mathbf{R}^{N \times N}$ 描述线路拓扑关系。考虑到系统发生不平衡故障时产生零序电流, 加入 $\mathbf{I}_0 = \mathbf{I}_a + \mathbf{I}_b + \mathbf{I}_c$ 的维度提高故障检测准确率, 令 $\mathbf{V}_0 = 0$ 使节点特征维度相等, 得到维度为 4×64 图特征向量 \mathbf{X}_f , 表达式如下:

$$\mathbf{X}_f = (\mathbf{I}_f, \mathbf{V}_f) = (\mathbf{a}^\top, \mathbf{b}^\top, \mathbf{c}^\top, \mathbf{o}^\top)^\top \quad (2)$$

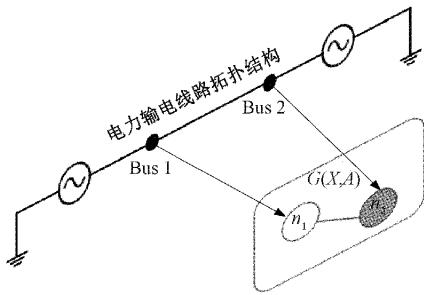


图 2 输电线路拓扑结构映射为图数据

$$\mathbf{a} = \begin{bmatrix} I_{a,1} & V_{a,1} \\ \vdots & \vdots \\ I_{a,64} & V_{a,64} \end{bmatrix}, \mathbf{b} = \begin{bmatrix} I_{b,1} & V_{b,1} \\ \vdots & \vdots \\ I_{b,64} & V_{b,64} \end{bmatrix} \quad (3)$$

$$\mathbf{c} = \begin{bmatrix} I_{c,1} & V_{c,1} \\ \vdots & \vdots \\ I_{c,64} & V_{c,64} \end{bmatrix}, \mathbf{o} = \begin{bmatrix} I_{o,1} & V_{o,1} \\ \vdots & \vdots \\ I_{o,64} & V_{o,64} \end{bmatrix} \quad (4)$$

式中: \mathbf{X}_f 为故障类型 f 的图特征向量, $I_{a,t}, V_{a,t}$ 分别为第 t 个采样点的 A 相瞬时电流电压。

2) 图注意力层:通过节点特征聚合和注意力机制两个操作提取图特征。

(1) 节点特征聚合:GAT 网络层首先聚合图的邻居节点特征信息,层级传播公式如下:

$$\mathbf{X}^{(l+1)} = \sigma(\tilde{\mathbf{D}} - \frac{1}{2}\tilde{\mathbf{A}}\tilde{\mathbf{D}} - \frac{1}{2}\mathbf{X}^{(l)}) \quad (5)$$

式中: $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}$, \mathbf{I} 为单位矩阵, $\tilde{\mathbf{D}}$ 为 $\tilde{\mathbf{A}}$ 的度矩阵, $\mathbf{X}^{(l)}$ 为第 l 层的特征矩阵, $\mathbf{W}^{(l)}$ 为训练权重矩阵, σ 为 ReLU 激活函数。

(2) 注意力机制:GAT 的核心操作为注意力机制,提高对邻接节点特征进行权重分配,能自适应不同拓扑结构的输电线路特性,注意力机制表达式如下:

$$\text{Attention}(\mathbf{Q}, \mathbf{S}) = \sum_i \langle \mathbf{Q}, \mathbf{T}_i \rangle \cdot \mathbf{T}_i \quad (6)$$

式中: \mathbf{Q} 为先验信息, \mathbf{S} 为需要被处理的信息源, \mathbf{T}_i 为 \mathbf{Q} 的向量表达。如图 3(a) 所示, GAT 中用一个以注意力机制为核心的聚合操作得到每个节点新的特征向量。每层 GAL 的输入是节点特征向量集合 \mathbf{X} , 输出是通过信息聚合后新的节点特征向量集合 \mathbf{X}' , 表达式如下:

$$\mathbf{X} = \{\vec{x}_1, \vec{x}_2, \dots, \vec{x}_N\}, \vec{x}_i \in R^F \quad (7)$$

$$\mathbf{X}' = \{\vec{x}'_1, \vec{x}'_2, \dots, \vec{x}'_N\}, \vec{x}'_i \in R^F \quad (8)$$

式中: N 为图节点个数, \vec{x}_i, \vec{x}'_i 分别为节点 i 的特征向量和经过 GAL 新的节点特征向量, F 为节点的特征维度。设图的中心节点为 \vec{x}_i , 其对应的邻居节点为 \vec{x}_j , 则节点 \vec{x}_i 到节点 \vec{x}_j 的权重系数计算公式如下:

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(\vec{a}^T [\mathbf{W}\vec{x}_i \| \mathbf{W}\vec{x}_j]))}{\sum_{n_k \in N(n_i)} \exp(\text{LeakyReLU}(\vec{a}^T [\mathbf{W}\vec{x}_i \| \mathbf{W}\vec{x}_k]))} \quad (9)$$

其中, α_{ij} 为注意力系数, \vec{a}^T 表示计算函数, $\|$ 表示向量的拼接, LeakyReLU 为非线性激活函数, \mathbf{W} 表示图注意

力节点从输入到输出的特征维度变换矩阵。如图 3(b) 所示, 得到所有的权重系数后, 根据注意力机制加权求和的思路, 特征聚合后节点新的特征向量 \vec{x}'_i 为:

$$\vec{x}'_i = \sigma \left(\sum_{v_j \in N(n_i)} \alpha_{ij} \mathbf{W} \vec{x}_j \right) \quad (10)$$

式中: \vec{x}'_i 是 \vec{x}_i 在 GAL 融合了所有邻居节点信息新的特征向量, σ 为 eLU 函数表达式如下:

$$\sigma = \begin{cases} x, & x \geq 0 \\ \beta(e^x - 1), & x < 0 \end{cases} \quad (11)$$

式中: eLU 为 ReLU 的一个改进型, 右侧为线性, 左侧具有软饱和性, 线性部分缓解梯度消失的问题, 左侧的软饱和区加速训练的收敛。

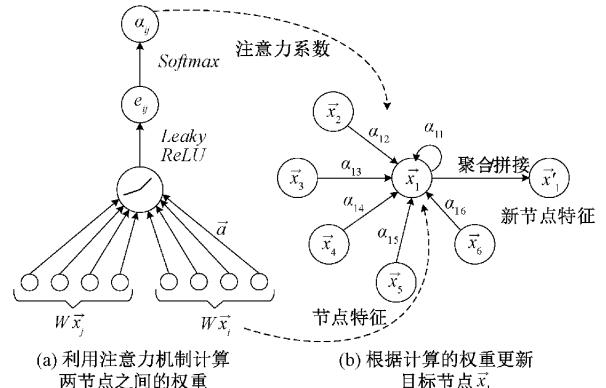


图 3 图注意力层结构

3) 读出层:通过 GAL 得到图节点特征表示后, 为了实现图分类任务, 需要得到整图的特征表示, 因此通过读出层对节点特征向量进行聚合, 得到整个图的特征表示, 使用的读出层函数如下:

$$\mathbf{X}_G = \sigma \left(\frac{1}{|N|} \sum_i^N \vec{x}_i \right) \quad (12)$$

式中: \mathbf{X}_G 为整个图的特征表示, N 为节点数量, \vec{x}_i 为节点 i 的特征向量, σ 表示 sigmoid 激活函数。

4) 全连接层与输出层: 读出层得到整图特征信息后, 为了提高模型的泛化能力, 在线性层之前使用了一个 Dropout 层, 丢弃率设置为 0.3。再使用线性层对得到的图特征 \mathbf{X}_G 进行线性转换, 得到新的特征向量表示 \mathbf{H}_G , 利用 softmax 函数得到最终模型预测标签概率 \hat{y} , 表达式如下:

$$\hat{y} = \text{softmax}(\mathbf{H}_G) \quad (13)$$

处理多分类问题, 通常使用交叉熵函数作为损失函数, 用于计算 GAT 故障诊断模型的预测标签和真实标签之间的损失值, 其数学表达式为:

$$\text{loss} = -\frac{1}{n} \sum_{i=1}^n \sum_{k=1}^m y_{ik} \log \hat{y}_{ik} \quad (14)$$

式中: n 为训练的样本数; m 为类别数; y_{ik} 数据样本的真实标签, 输出层得到最终模型预测的样本标签 \hat{y}_i 。

1.2 基于 GAT 的故障诊断算法流程

本文提出的智能故障诊断算法包含数据预处理阶段、

训练阶段、验证阶段、测试阶段三个阶段,流程如图 4 所示。

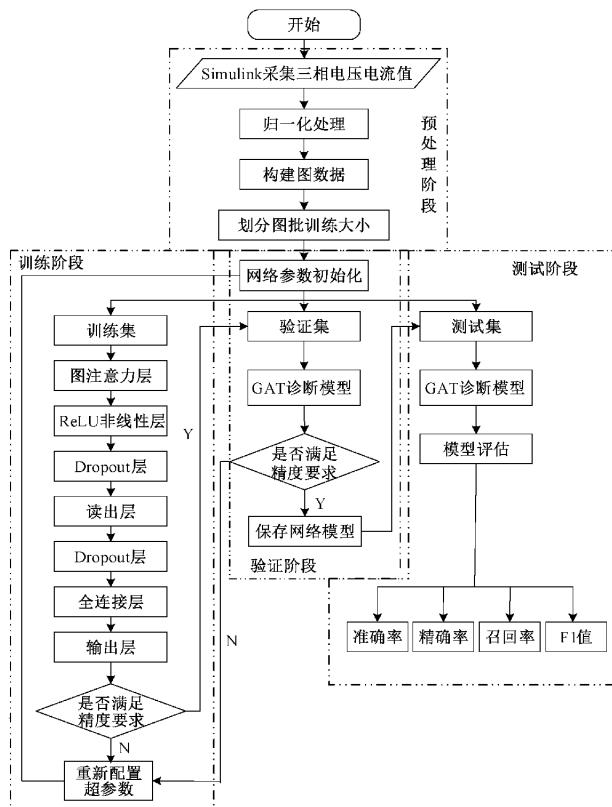


图 4 基于 GAT 的故障诊断流程

1) 数据预处理阶段:首先通过 Simulink 仿真平台搭建的 400 kV 三相输电线系统,采样故障后 3 个周期三相电流电压序列,并对信号做标准化处理将原始序列转换为图数据。为了更高效地训练网络模型,我们采用了图小批量训练(mini-batch),考虑到不同图节点之间没有消息交换,且邻接矩阵为稀疏矩阵。如图 5 所示,图训练批量大小(batch-size)为 2,将小图邻接矩阵 A_1, A_2 以对角形式拼接与特征向量 X_1, X_2 合并成大图特征信息。最后将数据集以 8 : 1 : 1 的比例划分为训练集、验证集、测试集,分别用于模型参数训练、模型选择和模型性能测试。

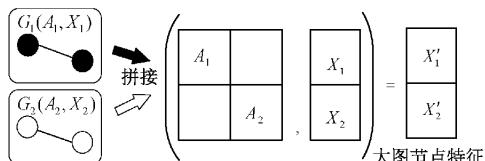


图 5 批量大小为 2 的图小批量训练

2) 训练阶段:首先初始化网络参数,然后通过各网络层进行前向传播,为了防止训练过拟合,每个 GAT 包含 ReLU 非线性层和 Dropout 层对数据样本作乱序处理。然后判断输出层是否满足精度要求,若满足则进入测试阶段,若不满足,通过 Adam 优化器反向传播误差更新网络参数,直到完成规定迭代次数。

3) 验证阶段:在验证集上对训练后的网络模型进行验证,若满足精度要求则进入测试阶段,若不满足精度要求,则重新配置超参数返回训练阶段。

4) 测试阶段:深度学习分类模型常用的评价指标为准 确率(accuracy score)、精确率(precision score)、召回率(recall score)、F1 值(f1 score),其中准确率为所有样本中预测正确的比例,精确率为预测结果为正类样本中将正类预测正确的比例,召回率为实际的正类样本中将预测正确的正类比例,F1 值即为精确率和召回率的调和平均数,我们以这四种评价指标对模型进行性能评估,得到性能最优 GAT 故障诊断模型。

2 案例分析与讨论

本文实验使用的深度学习框架为 Pytorch, 版本为 1.9.0, 搭载 python3.8, Cuda11.1 的版本, 系统为 Ubuntu18.04, 三相电流电压数据采集软件为 MATLAB2021b, 服务器设备 GPU 为 RTXA4000, 显存为 16 GB, CPU 处理器为 6 核 Intel (R) Xeon (R) Silver4310cpu@2.10 GHz。

2.1 实验数据采集

在实际电力系统运行中,短路故障是发生频次最高危害最大的故障来源,如图 6 所示,通过 MATLAB/Simulink 仿真平台搭建两端电压源等级为 400 kV, 工作频率为 50 Hz, 线路长度为 300 km 的三相输电线路仿真系统,其中 Load1、Load2 为电压源两端的负载, Bus1、Bus2 为系统总线。

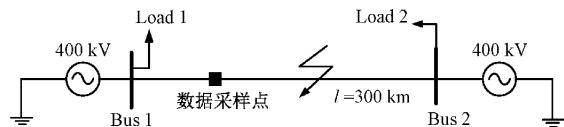


图 6 三相输电线路系统模型

如表 1 所示,仿真模型通过三相故障模块分别产生 5 种短路故障:单相接地短路(LG)、两相短路(LL)、两向接地短路(LLG)、三相短路(LLL)、三相接地短路(LLLG),如表 1 所示,分别采样 11 种故障线路位置、20 种随机时刻的故障数据、5 种故障过渡阻值、6 种故障类型的故障工况数据,其中采样频率为 1 000 Hz, 共采样 $11 \times 20 \times 5 \times 5 = 5500$ 组故障数据和 2 360 组无故障数据作为故障诊断数据集。

表 1 故障参数设置

参数类型	参数范围	参数数量
故障位置	1%、10%、20%、…、90%、99%	11
故障时刻	0~0.1 s	20
过渡电阻	0.5 Ω、1 Ω、10 Ω、25 Ω、50 Ω	5
故障类型	NF、LG、LL、LLG、LLL、LLLG	6

2.2 GAT 故障诊断模型参数选择

设定模型训练的 epoch 为 100, 实验数据集根据批尺寸划分相应的训练次数, 本文针对 GAL 的层数选择、GAL 隐藏维度的选择、图批量大小的选择进行了相应的实验分析, 分别通过对比训练集、验证集的准确率以及测试集的 4 种评估指标选择性能最优的超参数。

1) GAL 的层数选择: 由表 2 知 GAL 的层数选择对故障诊断模型的性能影响较大, 结果表明使用 3 层 GAL 的特征提取效果最佳, 故障诊断的准确率最高, 而当层数为 2 和 4 时, 模型准确率低, 且层数越多训练耗时越长, 综合考虑选择 3 层 GAL 来提取图数据特征。

表 2 不同数量 GAL 的模型 %

层数	故障诊断准确率			评估指标		
	训练集	验证集	测试集	精确率	召回率	F1 值
2	80.00	84.36	83.97	81.97	81.47	81.50
3	100	100	99.98	99.81	99.82	99.82
4	86.6	86.79	85.64	83.72	83.56	83.67

2) GAL 隐藏维度的选择: 在确定 GAL 层数为 3 的前提下, 分别对 16、32、64、128 四种 GAL 隐藏维度进行实验, 由表 3 知当隐藏维度为 64 时, GAT 模型故障诊断准确率最佳且评估性能最优, 其测试集准确率高达 99.98%。

表 3 不同 GAL 隐藏维度的故障诊断准确率 %

GAL 维度	故障诊断准确率			评估指标		
	训练集	验证集	测试集	精确率	召回率	F1 值
16	100	99.49	99.35	99.35	99.40	99.37
32	100	99.87	99.74	99.75	99.69	99.72
64	100	100	99.98	99.81	99.82	99.82
128	100	99.36	99.60	99.24	99.43	99.34

3) 图批量大小的选择: 在满足上述参数条件后, 分别设置 16、32、64 的 batch-size 对模型进行训练。由表 4 知不同 batch-size 的训练集、验证集、测试集的故障诊断准确率相差甚微, 当 batch-size 为 32 和 16 时模型准确率高, 且 batch-size 越小, 训练时间越长, batch-size 为 32 时训练时长较短, 综合性能考虑选择 batch-size 为 32。

表 4 不同批量大小的故障诊断准确率 %

批量 大小	故障诊断准确率			评估指标		
	训练集	验证集	测试集	精确率	召回率	F1 值
16	100	100	99.67	99.80	99.78	99.79
32	100	100	99.84	99.88	99.86	99.80
64	100	98.70	98.86	99.61	99.62	98.62

综上所述, 通过多次训练调试最终确定具有最优性能的 GAT 故障诊断模型, 使用 Adam 优化器反向传播进行

权值优化调整, GAL 和线性层分别设置两种丢弃率提高模型泛化性, 防止训练过拟合, 具体网络超参数设定如表 5。

表 5 GAT 故障诊断模型超参数

输入数据维度	6
图节点维度, 图节点特征维度	2,4
序列长度	64
输出维数	6
GAL 隐藏维度	64
GAL 层数	3
批量大小	32
学习率	0.01
丢弃率	0.1,0.3
激活函数	ReLU,eLU,softmax

2.3 实验结果分析

为了评估本文故障诊断方法的性能, 引入混淆矩阵分析 GAT 故障诊断模型各个类别的准确率, 混淆矩阵每行表示数据样本的真实标签(实际类别), 每列表示模型分类所得的预测标签(模型输出), 由图 7 可以观察到, 故障类型 LG、LL、LLLG 分类准确率为 100%, 而 NF、LLG、LLL 仅存在个别的误判情况, 不排除数据集采样存在一定的误差, 结果表明本文模型的故障诊断效果良好。

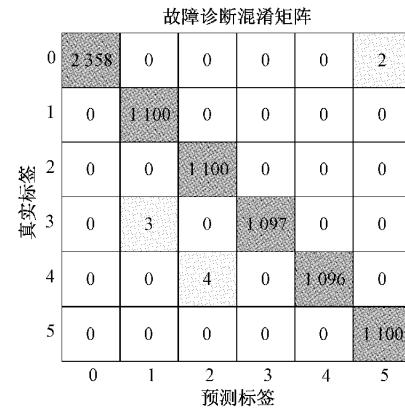


图 7 GAT 模型故障诊断混淆矩阵

为进一步测试本文故障诊断方法的性能, 使用 780 组数据为测试集进行测试, 其中 LG、LL、LLG、LLL、LLLG 五种故障类型每种 110 组数据, NF 无故障 230 组数据, 如图 8 所示, 模型故障诊断准确率高达 99.87%, 说明本文方法可以有效地检测是否发生故障以及各短路故障的类型, 综上所述, 本文所提出模型故障诊断识别率高, 为解决电力系统输电线路故障诊断问题提供了一种良好的解决方案。

2.4 抗噪声性能试验

在实际电力输电线路系统中, 存在着各式各样的噪声源, 考虑实际工程应用, 要求模型具备良好的抗噪声性能, 因此我们在划分好的测试集上加入了不同程度的高斯白噪

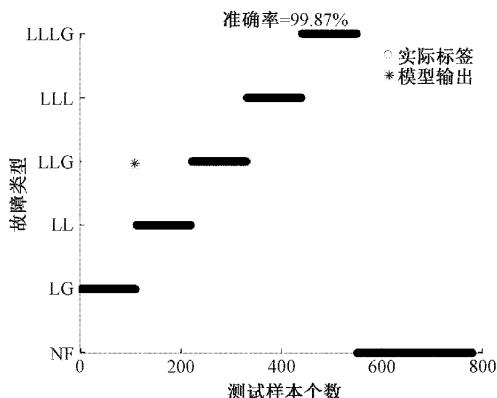


图 8 GAT 模型故障诊断结果

声,在不改变模型的任何参数下,以上述评价指标测试本文提出的故障诊断模型的抗噪声性能。由图 9 可知,该方法在 10%、15%、20%、25% 的高斯白噪声下,随着白噪声的增大性能会有一定程度的下降,但故障诊断方法仍然准确有效。

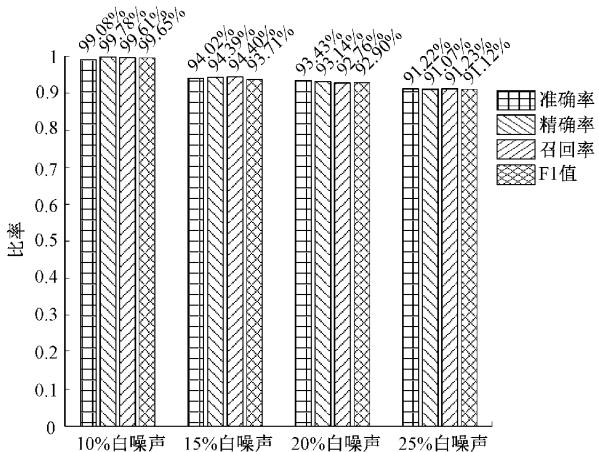
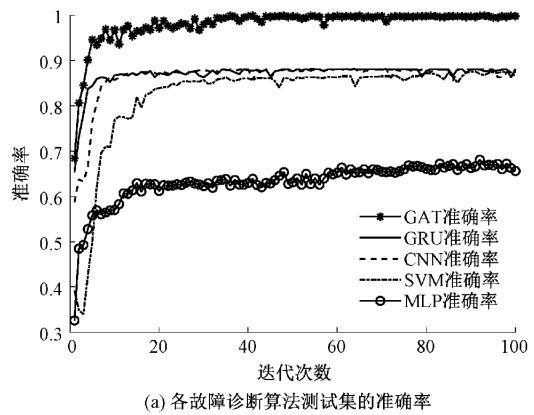


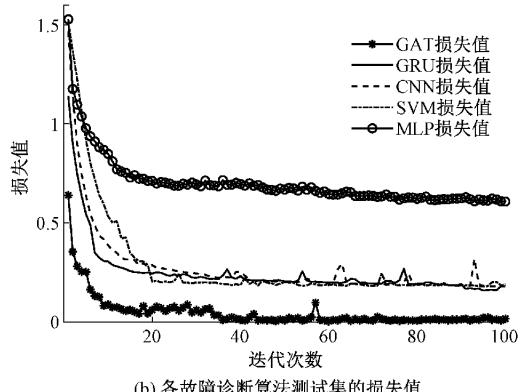
图 9 不同高斯白噪声下 GAT 模型诊断效果

2.5 与其他算法对比

在同一设备环境下,将本文提出方法与其他智能算法作对比,故障数据集按 8 : 1 : 1 的比例随机划分为训练集、验证集与测试集。其中分别设置 GRU 模型学习率为 0.001, 隐藏层维度为 16, 丢弃率为 0.3; CNN 模型学习率为 0.001, 隐藏层维度为 16, 丢弃率为 0.2; SVM 使用 scikit-learn 机器学习库, 惩罚系数为 1, 采用 ploy 核函数; MLP 模型隐藏层维度为 8, 丢弃率为 0.3, 学习率为 0.001; 各算法模型均训练 100 epoch, 如图 10 分别为门控循环单元 GRU、卷积神经网络 CNN、支持向量机 SVM、多层感知器 MLP 分类模型测试集损失值和准确率,可以观察出,GAT 收敛速度最快,GRU 其次,MLP 收敛速度最差。GAT 在第 2 个 epoch 开始收敛,在 30~40 epoch 时其损失值和准确率趋于稳定,如图 10 可以观察到,GAT 的损失值最低,准确率最高,模型性能最佳。



(a) 各故障诊断算法测试集的准确率



(b) 各故障诊断算法测试集的损失值

图 10 各故障诊断算法测试集损失值与准确率

为了突出 GAT 模型性能的优越性,以准确率、精确率、召回率、F1 值 4 种评价指标比较各智能算法。如图 11 所示,GAT 模型具备更好的故障诊断性能,其各指标性能均优于门控循环单元 GRU、卷积神经网络 CNN、支持向量机 SVM、多层感知器 MLP 分类模型,从而验证了本文提出的 GAT 故障诊断模型应用于输电线路系统上的有效性。

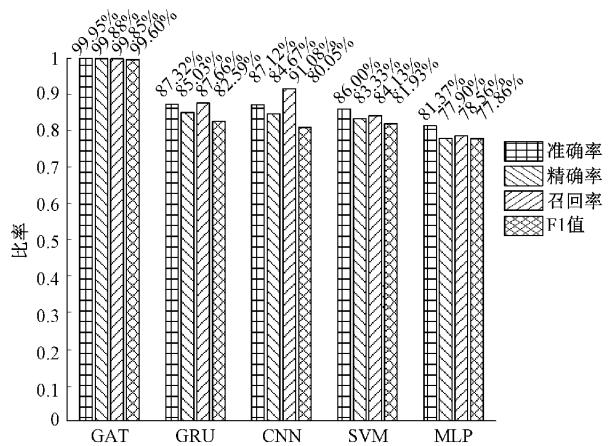


图 11 各故障诊断算法 4 种评估指标对比

2.6 与现阶段其他方法对比

为体现本文提出的输电线路故障诊断方法的优越性,将提出的故障诊断模型与现有文献的工作成果进行比较,

结果如表 6 所示。从表中可以看出, ANN 依赖人工特征提取和选择, 而 1D-CNN 和 GAT 直接以原始信号作为输入, 通过网络模型的训练, 自适应地获取各类故障特征。结果表明, 本文提出的 GAT 故障诊断模型在输电线路系统中具备最高的分类精度(99.87%), 同时在噪声存在的情况下依然保持 91.22% 以上的诊断精度, 从而验证该方法的先进性。

表 6 各故障诊断算法对比结果

方法	诊断模型	是否实现 故障检测	是否测试 抗噪声性能	分类 准确率/%
文献[21]	ANN	是	否	78.10
文献[22]	DWT-ANN	是	否	97.43
文献[23]	1D-CNN	否	否	98.73
本文方法	GAT	是	是	99.87

2.7 应用于其他电力输电线路系统

为验证本文提出方法在电力系统故障诊断的有效性和实用性, 如图 12 所示, 通过 Simulink 仿真平台, 在 IEEE13 总线测试系统上分别设置 line632-633、line671-680、line692-675 三条故障输电线路进行测试。该系统为修改后的三相不平衡径向分布的中压电网系统, 电源电压等级为 4.16 kV, 系统频率为 60 Hz, 总负荷功率为 50 MVA, 光伏分布式电源(DG-PV)由 4 个 187.5 V 的光伏发电单元串联而成, 再通过升压变压器 T2 连接到节点 680, T1, T2 为系统变压器(4.16 kV/480 V), 负载 L1~L10 为三相负载, 负载 L2~L6 为单相负载。

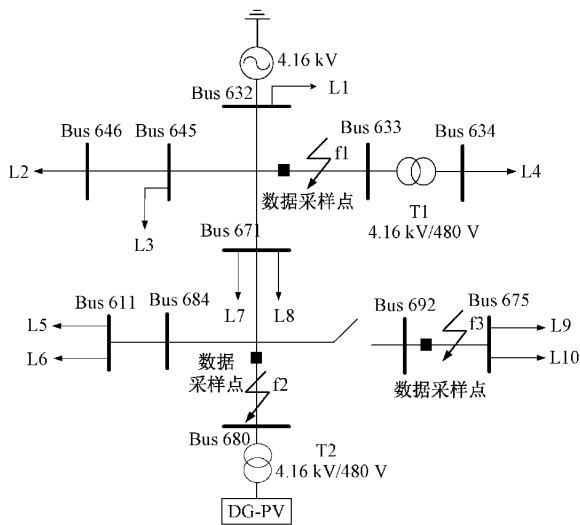


图 12 IEEE13 总线测试系统

采用本文提出的 GAT 故障诊断模型, 依次对 IEEE13 系统 3 条故障输电线路 6 种情况(LG, LL, LLG, LLL, LLLG, NF)进行数据采集, 即当 line632-633 为故障线路时, 其余两条输电线路运行情况为正常。图构建时仅需考虑故障输电线路拓扑信息(即 line632-633 仅考虑 Bus632

与 Bus633, line671-680 仅考虑 Bus671 与 Bus680, line692-675 仅考虑 Bus692 与 Bus675), 不需要考虑整个电网系统的拓扑结构, 这样不仅简化了图结构, 减少了不必要的计算量, 同时提升了 GAT 模型的训练效率。输入为故障后采样点的三相电流电压值, 其中数据归一化处理与图构建(图特征维度 4×64)、输入维度、故障参数设置与上述 400 kV 三相输电线路仿真系统保持一致, 在模型训练 100 epoch 后, 测试 780 组数据, 得到如表 7 的诊断结果。

表 7 测试系统三条输电线路的故障诊断结果

故障输电 线路	测试数据 数量	准确率/ %	精确率/ %	召回率/ %	F1 值/ %
Line632-633	780	99.76	99.72	99.74	99.73
Line671-680	780	99.65	99.64	99.66	99.65
Line692-675	780	99.85	99.82	99.82	99.81
总计	2340	99.75	99.73	99.74	99.73

结果表明, 本文提出的 GAT 模型在 IEEE13 总线测试系统的输电线路中仍然适用, 综合达到 99.75% 的诊断准确率, 精确率、召回率、F1 值总体达到 99.73% 以上。尽管本文提出的方案在故障诊断方面有着不错的检测与分类效果, 但本文方法也存在一定的缺陷, 若故障过渡电阻阻值过大或数据采样间隔过高, 可能会导致暂态电流电压特征不明显, 这是故障诊断出现误差的主要原因。随着电力系统逐步数字化与智能化, 将现代智能通信设备与深度学习算法结合以简化故障诊断方法, 更适用于实际工程技术中。

3 结论

本文针对传统故障诊断方法依赖人工特征工程的问题, 同时考虑了输电线路的拓扑特性, 建立了一种基于 GAT 的端到端智能故障诊断模型。通过 MATLAB/Simulink 仿真平台采集 400 kV 三相输电线路系统和 IEEE13 总线测试系统的 6 类故障数据, 对提出模型进行案例分析, 得出下述结论:

GAT 算法适用于建立含输电系统拓扑信息的故障诊断模型, 相较于传统的故障诊断方法, 该方法无需人工特征提取过程, 直接将原始故障信号转化为图形式, 通过 GAT 自动获取特征信息并进行分类, GAT 的注意力机制更好地聚焦故障的特征信息。本文方案具有 99.8% 以上故障识别率, 不受故障初始相角、故障过渡电阻、故障位置等因素的影响, 加入不同程度的白噪声, 模型仍具备良好的鲁棒性和抗干扰能力。通过与 GRU、CNN、SVM、MLP 四种算法及与现有文献提出的 3 种故障诊断方法对比, 本文提出算法故障分类精度最高。该算法为输电线路系统的故障诊断提供了一种新的研究思路。

参考文献

- [1] YU J J Q, HOU Y, LAM 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.
- [2] KAR S, SAMANTARAY S R, ZADEH M D. Data-mining model based intelligent differential microgrid protection scheme[J]. IEEE, 2017, 11(2): 1161-1169.
- [3] 费春国,霍洪双.基于电流振幅与 SVM 的输电线路故障分类[J].电力系统及其自动化学报,2019,31(4): 139-144.
- [4] FERREIRA V H, ZANGHI R, FORTES M Z, et al. A survey on intelligent system application to fault diagnosis in electric power system transmission lines[J]. Electric Power Systems Research, 2016, 136: (135-153).
- [5] MISHRA D P, RAY P. Fault detection location and classification of a transmission line[J]. Neural Comput and Applic, 2018, 30: 1377-1424.
- [6] EKTA P, SURYANARAYANA G. Local end data based fault detection technique in transmission line using DWT[C]. 2020 IEEE Students Conference on Engineering & Systems(SCES), 2020: 1-6.
- [7] KRISHNANAND K R, DASH P K. A new real-time fast discrete S-transform for cross-differential protection of shunt-compensated power systems[J]. IEEE Transactions on Power Delivery, 2013, 28(1): 402-410.
- [8] RAY P, MISHRA D P. Support vector machine based fault classification and location of a long transmission line[J]. Engineering Science and Technology, 2016, 19(3): 1368-1380.
- [9] 吴笑民,曹卫华,王典洪,等.多支持向量机模型的输电线路故障诊断方法[J].高电压技术,2020,46(3): 957-963.
- [10] SHARIF A A, KAREGAR H K, ESMAEILBEIGI S. Fault detection and location in DC microgrids by recurrent neural networks and decision tree classifier[C]. 2020 10th Smart Grid Conference(SGC), 2020: 1-6.
- [11] ABDULLAH A. Ultrafast transmission line fault detection using a DWT-based ANN [J]. IEEE Transactions on Industry Applications, 2018, 54(2): 1182-1193.
- [12] 杨杰,吴浩,董星星,等.基于电流故障分量特征和随机森林的输电线路故障类型识别[J].电力系统保护控制,2021,49(13): 53-63.
- [13] CHEN J H, GAO J, JIN Y W, et al. Fault diagnosis in distributed power-generation systems using wavelet based artificial neural network[J]. European Journal of Electrical Engineering, 2021, 23(1): 53-59.
- [14] 刘辉,李永康,高放,等.基于小波散射协同 BiLSTM 的输电线路故障诊断[J].国外电子测量技术,2021, 40(12): 165-172.
- [15] GRCIC I, PANDZIC H. Fault detection in DC microgrids using recurrent neural networks[C]. 2021 International Conference on Smart Energy Systems and Technologies(SEST), 2021: 1-6.
- [16] FAHIM S R, SARKER R I, ARIFUZZAMAN, et al. A novel approach to fault diagnosis of high voltage transmission line-a self attentive convolutional neural network model[C]. 2020 IEEE Region 10 Symposium (TENSYMP), 2020: 1329-1332.
- [17] THOMAS N, WELLING M. Semi-supervised classification with graph convolutional networks[C]. ICLR 2017 Conference, 2017: 1-14.
- [18] WU F, SOUZA A, ZHANG T. Simplifying graph convolutional networks[C]. International Conference on Machine Learning. PMLR, 2019: 6861-6871.
- [19] 徐冰冰,岑科廷,黄俊杰,等.图卷积神经网络综述[J].计算机学报,2020,43(5): 755-780.
- [20] 钟智,管霖,苏寅生,等.基于图注意力深度网络的电力系统暂态稳定评估[J].电网技术,2021, 45 (6): 2122-2130.
- [21] JAMIL M, SHARMA S K, SINGH R. Fault detection and classification in electrical power transmission system using artificial neural network[J]. Springer Plus, 2015(4): 334.
- [22] RAY P, MISHRA D P, DEY K, et al. Fault detection and classification of a transmission line using discrete wavelet transform & artificial neural network[C]. 2017 International Conference on Information Technology(ICIT), 2017: 178-183.
- [23] APARNNA A, SABEENA B K, SERENE B, et al. A modified CNN for detection of faults during power swing in transmission lines[C]. 2020 International Conference on Power, Instrumentation, Control and Computing(PICC), 2020: 1-5.

作者简介

- 唐 阖,硕士,主要研究方向为电力系统故障诊断等。
E-mail: 982547886@qq.com
- 高彦杰,博士,主要研究方向为人工智能及智能控制系统,微电网控制,电力电子系统等。
E-mail: 410919132@qq.com
- 汪长虹,硕士,主要研究方向为微电网特征分析等。
E-mail: maktub522@163.com