

基于改进图卷积神经网络的配网线路故障诊断

黄文栋[†], 张雨, 阮启洋, 许卓佳, 杨溢儒

(广东电网有限公司 广州供电局, 广东 广州 510000)

摘要:随着电网的不断扩容,系统结构越来越复杂,多故障频发,而多故障是故障诊断的关键和难点。为解决故障处理数据量大,需要快速、准确地诊断电网故障的问题,本文提出了一种基于模糊优化图卷积神经网络的配网故障诊断模型。首先处理采集的配网故障线路的特征数据;其次,搭建基于图卷积神经网络的故障诊断模型,利用模糊理论建立配电网故障的隶属函数;最后利用训练好的模型进行配网故障诊断。仿真结果表明,模糊优化图卷积神经网络对多故障诊断的准确率高于卷积神经网络以及其他方法,本文方法做出的诊断结果更加精确,综合诊断效果最好。

关键词:模糊优化;图卷积神经网络;配电网;故障诊断;分类器

中图分类号:TM273

文献标识码:A

Distribution Network Line Fault Diagnosis Based on Improved Graph Convolutional Neural Network

HUANG Wendong[†], ZHANG Yu, RUAN Qiyang, XU Zhuojia, YANG Yiru

(Guangzhou Power Supply Bureau, Guangdong Power Grid Co., Ltd., Guangzhou, Guangdong 510000, China)

Abstract: With the continuous expansion of power grid, the system structure becomes more and more complex, and multiple faults occur frequently, which is the key and difficult point of fault diagnosis. In order to solve the problem of the large amount of fault processing data and the need for fast and accurate fault diagnosis of power grid, a fault diagnosis model of distribution network based on fuzzy optimized graph convolution neural network is proposed in this paper. Firstly, the collected characteristic data of distribution network fault lines are processed. Secondly, a fault diagnosis model based on graph convolutional neural network is built, and the membership function of distribution network faults is established by fuzzy theory. Finally, the trained model is used to diagnose the distribution network faults. The simulation results show that the accuracy of fuzzy optimized graph convolutional neural network for multi-fault diagnosis is higher than that of convolutional neural network and other methods. The diagnosis results of the proposed method are more accurate and the comprehensive diagnosis effect is the best.

Key words: fuzzy optimization; graph convolutional neural network; distribution network; fault diagnosis; classification unit

配电网是电力系统的重要组成部分,一旦发生中断,将严重影响人们的自然生活和生产,因此,及时、准确地定位和隔离故障对保证配电网的可靠性

和安全性具有重要意义^[1]。故障诊断包括检测、隔离和识别,故障诊断的主要任务是故障检测,即检查系统是否存在故障,并确定故障发生的时间;故

障隔离是对故障元件的区域进行隔离;故障识别是决定故障的种类、形式和大小^[2]。

图卷积神经网络(Graph Convolutional Network, GCN)作为深度学习的一个分支,在推荐系统、链接预测、节点分类、蛋白质结构推断等图结构数据中取得了突出的表现,为研究人员带来了新的机遇。在配电网故障诊断方法的发展方面,展现出许多令人印象深刻的成果。文献[3]提出一种基于卷积神经网络的评价模型,使用多个相同结构、不同参数的卷积神经网络构建综合评价模型,对电力系统的稳态特征量进行综合评估。文献[4]模糊 C 均值聚类的故障诊断模型,并通过计算故障可信度确定故障类型与位置。在文献[5]中,作者首次提出使用图神经网络进行停电预测,作者基于地区台站的天气测量数据建立台站网络拓扑模型,然后通过采集到的数据形成节点的特征,最后通过图神经网络进行信息的聚合和更新来预测每个数据点是不是故障的。在文献[6]中,作者采用 Defferrard 等人提出基于谱域的图卷积网络模型进行快速局部化谱过滤实现图卷积。不同的神经网络有不同的优点和缺点,许多学者利用其他理论方法来优化神经网络,以提高神经网络的效率,如模糊理论、免疫理论和遗传算法^[7-9]。

为了提高配电网中故障诊断的精确度,本文提出了一种基于模糊优化图卷积神经网络的配电网线路多重故障诊断方法。该方法具有诊断速度快、学习泛化能力强、鲁棒性强、准确快速判断故障类型和故障线路等优点^[10-11]。

1 图卷积神经网络和模糊理论

1.1 图卷积层的定义

目前,大多数图卷积层都有一个共同的架构,因为滤波器参数通常在图中的所有位置共享。对于这些图卷积层,目标是学习图结构化数据 $G=(V, E)$ 上的特征函数,该函数将配电网节点向量特征矩阵 $\mathbf{X}$ 和样本的邻接矩阵 $\mathbf{A}$ 作为输入:

$$\text{Input} = (\mathbf{X}, \mathbf{A}) \quad (1)$$

其中 $\mathbf{X}$ 是一个 $n \times d$ 特征矩阵,由每个节点 i 的特征描述 x_i 组成。 n 是节点数(n 是配网线路故障诊断中的样本数), d 是输入特征数。邻接矩阵以矩阵形式表示历史数据与当前样本之间的相似度量。

图卷积层的输出是一个 $N \times F$ 节点级向量 $\mathbf{Y}$, 其中 F 是转换器状态的数量。每个图卷积层都可

以写成非线性函数:

$$\mathbf{H}^{(i+1)} = f(\mathbf{H}^{(i)}, \mathbf{A}), i = 0, 1, \dots, L \quad (2)$$

其中 L 是图卷积层的数量。当 $i=0$ 时, $\mathbf{H}^{(0)}$ 与 $\mathbf{X}$ 相同。当 $i=L$ 时, $\mathbf{H}^{(L)}$ 与 $\mathbf{Y}$ 相同。特定的图卷积层仅在激活函数 f 的选择和参数化方式上有所不同。

1.2 GCN 的结构

通常,神经网络旨在通过输入配电网节点向量 $\mathbf{X}$ 来诊断配电网的故障类型 $\mathbf{Y}$ 。具体而言,GCN 除了 $\mathbf{X}$ 之外还需要一个 $n \times n$ 邻接矩阵 $\mathbf{A}$ 。设 n 表示数据集中的样本数。训练集和验证集中的样本仅链接到具有相同标签的样本。例如,如果第 i 个样本和第 j 个样本属于同一故障,则 $A(i, j) = A(j, i) = 1$ 。对于测试集中的样本(未知样本),Siamese 网络用于提取输入变量的低维特征,从而计算样本之间的欧几里得距离。然后,利用 KNN 找到最接近未知样本的 k 个样本,并认为它们是连通的。例如,如果 k 等于 1,则第 i 个未知样本和第 j 个样本的欧式距离最接近,则 $A(i, j) = A(j, i) = 1$ 。在这种情况下,邻接矩阵 $\mathbf{A}$ 可以表示历史数据和当前样本之间的相似度量^[12-14]。

为了说明 GCN 的结构,图 1 显示了一个简单的 GCN 模型,该模型包括两个图卷积层和两个密集层。




图 1 GCN 模型

显然,这种架构不同于图 2 中的传统神经网络(例如 MLP)。GCN 的输入数据 $(\mathbf{X}, \mathbf{A})$ 是图形式,利用内在拓扑结构生成中间特征,而 MLP 只使用配电网节点向量 $\mathbf{X}$ 作为输入数据,忽略了样本的相似性度量。如图 1 所示,图结构数据 $(\mathbf{X}, \mathbf{A})$ 被馈送到在第一层输出 $\mathbf{H}^{(1)}$ 的 GCN。具体来说,得到一个混合特征矩阵 $\hat{\mathbf{A}}^T \mathbf{X}$, 它使用 $\hat{\mathbf{A}}^T$ 表示的权重将每个节点的特征向量与相邻节点的特征向量线性组合。接下来,通过乘以权重矩阵 $\mathbf{W}_1$ 并加上偏置

向量 $\mathbf{b}_1$, 得到一组新的特征 $\mathbf{A}'' \mathbf{X} \mathbf{W}_1 + \mathbf{b}_1$ 。之后, 为新向量选择一个激活函数(例如 ReLU)以获得第一层 $\mathbf{H}^{(1)}$ 的输出数据:

$$\mathbf{H}^{(1)} = \text{ReLU}(\mathbf{A}'' \mathbf{X} \mathbf{W}_1 + \mathbf{b}_1) \quad (3)$$




图 2 MLP 模型

同理, 第二个图卷积层的输出数据为:

$$\mathbf{H}^{(2)} = \text{ReLU}(\mathbf{A}'' \mathbf{H}^{(1)} \mathbf{W}_2 + \mathbf{b}_2) \quad (4)$$

其中 $\mathbf{W}_2$ 和 $\mathbf{b}_2$ 分别是第二个图卷积层中的权重矩阵和偏置向量。

图卷积层后面有两个密集层。在输入 $\mathbf{H}^{(2)}$ 之前需要取胜数据。在第三层, 输出数据 $\mathbf{H}^{(3)}$ 可以通过权重矩阵 $\mathbf{W}_3$ 、偏置向量 $\mathbf{b}_3$ 和激活函数得到:

$$\mathbf{H}^{(3)} = \text{ReLU}(\mathbf{H}^{(2)} \mathbf{W}_3 + \mathbf{b}_3) \quad (5)$$

Softmax 函数的第四层输出为:

$$\mathbf{Y} = \text{Softmax}(\mathbf{H}^{(3)} \mathbf{W}_4 + \mathbf{b}_4) \quad (6)$$

其中 $\mathbf{Y}$ 是配网故障类型。

Softmax 是卷积神经网络的输出分类方法, 其原理是设置 n 个独立分类的输出个数为 n , 对应的索引号为 1 到 n , 索引号对应一个类别。 n 个输出(归一化在 0 和 1 之间)的最大输出值设置为 1, 其余输出值设置为 0, 输出为 1 的索引号是理想的分类, 所以 $W\{\text{True}\} = 1, W\{\text{False}\} = 0$ 。成本函数如下:

$$V(\gamma) = -\frac{1}{n} \left[\sum_{i=1}^n \sum_{j=1}^k \mathbf{W}\{y^{(i)} = j\} \log \frac{e^{\gamma_j^T x^{(i)}}}{\sum_{j=1}^k \gamma_j^T x^{(i)}} \right] \quad (7)$$

样本中类别 j 事件的概率表示为:

$$P(y^{(i)} = j | x^{(i)}; \gamma) = \frac{e^{\gamma_j^T x^{(i)}}}{\sum_{j=1}^k \gamma_j^T x^{(i)}} \quad (8)$$

1.3 模糊理论

为避免数据过拟合, 在图卷积神经网络的下采样层增加模糊层, 对图卷积神经网络进行优化, 得到新的目标函数:

$$J(W, Z) = \min [V(\gamma) + G(\gamma) + \frac{1}{2} \|\mathbf{W}\|_2^2] \quad (9)$$

其中 W 为 softmax 的成本函数; W 为模糊层的权重; B 为模糊层网络的偏置; G 为模糊约束不变量。

在属性约简过程中, 可以使用模糊集方法通过模糊隶属函数对内部元素进行分类, 从而获得信息损失小的约简。从零序列电流提取特征向量的隶属函数为:

$$\mu_i^j = \exp \left[\frac{-(x_i - c_{ij})^2}{\sigma_{ij}^2} \right], i = 1, 2, \dots, m; j = 1, 2, \dots, n \quad (10)$$

定义了零序电流基波分量故障测度的隶属函数, Q 为单元集合:

$$\mu_L = \begin{cases} 1A(L) \leq -0.5Q \\ \frac{[0.5Q - A(L)]}{Q} - 0.5Q < A(L) < 0.5Q \\ 0A(L) \geq 0.5Q \end{cases} \quad (11)$$

定义了零序电流五次谐波分量故障测度的隶属函数:

$$\mu_{5L} = \begin{cases} 1 - \frac{\max(\varphi'_{5L})}{180}, L = 0 \\ \frac{\varphi'_{5L}}{180}, L = 1, 2, \dots, n \end{cases} \quad (12)$$

模糊层的每个节点代表一个模糊规则。

式(13)计算了各模糊规则的适用性:

$$\tau_j = \min(\mu_{j_1}^1, \mu_{j_2}^2, \dots, \mu_{j_n}^n) (j = 1, 2, \dots, n), i_n \in \{1, 2, \dots, n\} \quad (13)$$

模糊优化减少了 softmax 的计算量和图卷积神经网络训练所需的数据量, 提高了图卷积神经网络的故障识别精度和泛化能力。

2 配电网故障数据

本文采用 BPA 模拟 IEEE39 节点系统生成样本数据, 如图 3 所示。假设发电节点的一部分相当于一个光伏电站, 另一部分相当于一个装机容量不同的电站。

配电网线路的多处故障需要输电线路两端的电压数据、各节点的电流和电压信号, 选择电流、零序电流基波分量和五次谐波分量作为特征数据组成特征矩阵 $\mathbf{X}$, 除了 $\mathbf{X}$ 外, 还需要 $n \times n$ 邻接矩阵 $\mathbf{A}$, 其中设 n 表示数据集集中的样本数, 本文主要解决两个依赖分类问题, 分类原理如表 1 所示。




图 3 IEEE39 节点系统仿真

其中,故障类型有 10 种,故障线有 45 种。设置输出端口号为 55。前 10 位输出用于故障诊断。每种故障类型对应输出中的一个索引号,索引号从 1 到 10 分别代表 AN(A 地短路)、BN(B 地短路)、CN(C 地短路)、AB(AB 两一相短路)、BC(BC 两相短路)、CA(CA 两相短路)、ABN(ABN 两相接
地短路)、BCN(BCN 两相接
地短路)、CAN(CAN 两相接
地短路)、ABC(ABC 三相短路)。10 路输出中,输出最大值设为 1,获取故障类型。用于 11~55 故障线诊断在索引号中,最大值设置为 1,最小值设置为 0。例如,21 号表示 21 号线出现故障。

表 1 输出分类及对应的索引号

类别		故障类型										故障线						
输出端口号		AN	BN	CN	AB	AC	BC	ABN	ACN	BCN	ABC	1	2	3	...	43	44	45
索引号		1	2	3	4	5	6	7	8	9	10	11	12	13	...	53	54	55

由于数据特征的数值差异较大,直接作为输入变量会影响模型的性能,甚至损失函数也难以收敛。因此,在输入 GCN 之前,特征应该通过最小-最大归一化方法映射到区间[0,1]:

$$x'_i = \frac{x_i - x_{i,\min}}{x_{i,\max} - x_{i,\min}}, i = 1, 2, \dots, \quad (14)$$

其中 x_i 和 x'_i 分别表示归一化前后的第 i 个特征。 $x_{i,\min}$ 和 $x_{i,\max}$ 分别表示第 i 个特征的最小值和最大值。

3 基于 GCN 的配电网故障诊断模型

本文的多故障诊断模型流程如图 4 所示。首先采集各节点电压数据,生成测试样本集和训练样本集;训练样本集训练模糊优化图卷积神经网络参数,测试样本集测试模糊优化卷积神经网络在多故障诊断结果中的准确性。

(1)数据预处理

将数据特征集作为 GCN 的输入变量,为了得到邻接矩阵 A ,使用 Siamese 网络提取输入变量的低维特征,从而计算样本之间的欧几里得距离。然后,利用 KNN 找到最接近未知样本的 k 个样本,并认为它们是连通的。此外,最小-最大归一化方法用于将输入数据转换为范围从 0 到 1 的值。

(2)数据重构与划分

邻接矩阵被重构为坐标格式的稀疏矩阵,因为

它包含大量的 0 元素,导致空间浪费。在数据集中,75%的样本用于训练 GCN,其余样本用于评估模型的性能。




图 4 基于模糊优化 GCN 的配电网故障诊断流程

(3)初始化 GCN 的结构和参数

为了提高故障诊断的准确率,需要在训练 GCN 之前探索出最佳的结构和参数。GCN 的结构和参数主要包括图卷积层数、迭代次数、邻接矩阵 A 的 k 大小、优化器的选择,GCN 的一个简单结构如表 2 所示。

表 2 GCN 的结构

层数	结构和参数	形状
1	$H^0 = \text{Input}(\text{shape} = (X.\text{shape}[1],))$	1×9
2	$H^1 = \text{GraphConv}(\text{filter} = 16, \text{ReLU})([H^0] + \text{Graph})$	1×16
3	$H^2 = \text{Dropout}(\text{rate} = 0.25)(H^1)$	1×16
4	$H^3 = \text{GraphConv}(\text{filter} = 8, \text{ReLU})([H^2] + \text{Graph})$	1×8
5	$H^4 = \text{Dropout}(\text{rate} = 0.25)(H^3)$	1×8
6	$Y = \text{Dense}(\text{unit} = 10, \text{Softmax})(H^4)$	1×10

(4)训练 GCN

反向传播算法用于完成 GCN 的训练过程,主要包括两个步骤:前向激励传播和后向权重更新。对于前向激励传播,输入变量经过多个图卷积层处理后传递到密集层,样本的标签由密集层输出,诊断结果和实际结果用于计算损失函数(误差)。对于后向权重更新,使用链式法则将误差从输出层传递到中间层,然后通过梯度下降法更新每一层的权重,当达到设定的迭代次数时,使用测试集来评估 GCN 的性能。

(5)模型评估指标

本文采用准确率(accuracy)、F1 值和召回的几何平均值(G-mean)用于评估模型的性能。F1 和 G-mean 都是积极的指标,换句话说,指标越大,性能越好。

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

(15)

$$F\text{-Measure} = \frac{(1 + \beta^2) \times \text{Recall} \times \text{Precision}}{\beta^2 \times \text{Recall} + \text{Precision}}$$

(16)

$$G\text{-Mean} = \sqrt{\text{TPR} \times \text{TP}}$$

(17)

4 实验分析

为验证本文所用方法的可行性,本文采用 IEEE39 节点系统,由于系统出现多次故障,故故障类型和故障线数大于等于 2,本文只考虑故障类型和故障线等于 2 的情况,样本总数为 48126 个,其中 36095 个作为训练样本,其余 12031 个作为测试样本。实验环境为 Anaconda 软件的 Spyder 平台,深度学习的框架是 Tensorflow1. 12. 0 和 Keras2. 2. 4。

为了清楚地观察 GCN 的训练过程,图 5 显示了损失函数随着迭代次数的增加而变化的趋势。




图 5 GCN 训练过程

在训练过程的早期,训练集的损失函数随着迭代次数的增加而迅速减小。当迭代次数大于 400 时,损失函数趋于一个常数,不再继续下降,说明 GCN 已经收敛。一般来说,GCN 的训练过程比较稳定,收敛速度快。为了保证 GCN 的收敛性,GCN 在 800 次迭代后用于诊断故障。

为了分析图卷积层数对 GCN 性能的影响,逐渐增加图卷积层数,统计不同层下测试集的指标,如表 3 所示。

表 3 不同层的测试结果

层数	Accuracy	F1	G-mean	参数数量
1	0.765	0.724	0.758	80
2	0.823	0.804	0.814	152
3	0.801	0.789	0.795	224
4	0.745	0.731	0.738	296
5	0.721	0.706	0.717	368

从表 3 可以得出以下结论:

(1)一开始的时候测试集结果随着图卷积层数的增加而增加,这表明 GCN 的性能逐渐变强。图卷积层数为 2 时,GCN 的准确率、F1 值和 G-mean 值最大,故障诊断性能最好。这一现象表明,通过少量的图卷积层难以挖掘配电网线路状态之间复杂的非线性关系,增加图卷积层数可以提高 GCN 的特征学习能力,从而提高故障诊断的准确性。

(2)此外,发现要训练的参数量随着图卷积层的增加而线性增加。当图卷积层数大于 2 时,如果在 GCN 中加入更多的卷积层,GCN 的性能会越来越差。这是因为数据集中的样本数量是有限的,过多的图卷积层不仅会增加待训练的 GCN 的参数,而且会消耗大量的训练时间,而且容易过拟合,降低诊断的准确率。

(3)一般来说,图卷积层的数量应该根据数据集的大小来确定。如果样本数量较少,则通过将图卷积层设置为 2 层,GCN 可以获得更好的性能。

为了验证基于模糊优化的图卷积神经网络多故障诊断的有效性和准确性,本文对配电网进行了不同条件下的测试。将计算结果与图卷积神经网络模型以及 CNN 模型的测试结果进行了比较,部分试验结果如表 4 所示:

表 4 不同算法对比结果

算法	Accuracy	F1	G-mean	训练时间/s
本文方法	0.826	0.804	0.819	428
GCN	0.784	0.762	0.785	498
CNN	0.768	0.733	0.761	589

表 4 分别反映了五种算法的准确率、F1 值 G-mean 值以及训练时间,由数据可知,与其他模型相比,模糊优化 GCN 模型的准确率相对较高,并且运行时长最短,说明模糊优化卷积神经网络在线路故障诊断中具有更高的准确率。

(4)最后,重要的是,CNN 和 GCN 都使用卷积层来提取输入数据的特征。不同之处在于后者还通过邻接矩阵考虑了未知样本和标记样本之间的相似性度量。GCN 的性能优于 CNN,这说明 CNN 忽略了样本之间的相似性度量,限制了故障诊断的准确性。GCN 不仅可以使用时图卷积层来探索特征与故障类型之间的关系,还可以考虑样本之间的相似性度量,从而更准确地诊断配电网的故障类型。

5 结 论

为了提高配电网故障诊断的准确性,提出了基于模糊优化图卷积神经网络的配网故障诊断方法,通过对比图卷积神经网络和模糊优化卷积神经网络

的训练结果可知,在多故障诊断中,模糊优化图卷积神经网络比图卷积神经网络具有更强的学习泛化能力和并行处理能力,该方法在电网多故障诊断中具有广阔的应用前景。

参考文献

[1] 寇为刚,李永祥,孙艳军. 电力系统故障诊断的研究现状与展望综述[J]. 自动化与仪器仪表, 2015(2): 4—6,9.

[2] 于洋,王同文,张骏,等. 5G 承载网下基于经验小波变换和卷积神经网络的配网故障诊断方法[J]. 科学技术与工程, 2021, 21(7): 2713—2719.

[3] 田芳,周孝信,史东宇,等. 基于卷积神经网络综合模型和稳态特征量的电力系统暂态稳定评估[J]. 中国电机工程学报, 2019,39 (14) : 4025—4032.

[4] 何俊涛,车仁飞,孟庆萌,等. 基于广域录波数据和 FCM 聚类的电 网故障诊断方法[J]. 电力自动化设备,2019,39(6) : 179—184.

[5] OWERKO D, GAMA F, RIBEIRO A. Predicting power outages using graph neural networks[C]. In: Proceedings of the 2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP). Anaheim, CA, USA: IEEE, 2018, 26—29:743—747.

[6] CHEN K, HU J, ZHANG Y, et al. Fault location in power distribution systems via deep graph convolutional networks. [J]. arXiv preprint arXiv:1812.09464, 2018.

[7] 黄吴镝. 基于智能算法的输配网故障诊断研究[D]. 济南:山东大学,2020.

[8] 田岑. 基于不同信息源的配电网故障诊断方法研究[D]. 上海:上海交通大学, 2019.

[9] 翟海保,王兴志,葛敏辉,等. 基于改进卷积神经网络的输电线路故障诊断方法[J]. 电气自动化,2021,43(2):105—108.

[10] 孔祥轩,郑楚韬,仇志成,等. 基于广义深度学习的含 DG 配网故障诊断方法[J]. 电网与清洁能源,2020,36(11):53—57.

[11] 彭刚,唐松平,曾力,等. 基于数据挖掘的电网故障关联规则的研究[J]. 计算机与数字工程,2019,47(9):2369—2374.

[12] LAN H, ZHU F. Faulty line detection method for distribution network based on fuzzy rough sets and GA-BP neural network[J]. Southern Power System Technology, 2013,7 (1):90—94.

[13] LIU K, SU T, WANG D. Remot sensing aircraft recognition based on blur-invariant convolution neural network[J]. Laser & Optoelectronics Progress, 2018,55(8):393—400.

[14] WEI D, GONG Q, LAI W, et al. Research on internal and external fault diagnosis and fault-selection of transmission line based on convolution neural network[C]. Proceeding of CSEE, 2016,36., 21—28.