

刘华, 刘江永. 基于图卷积神经网络的电力变压器故障诊断[J]. 湖南科技大学学报(自然科学版), 2021, 36(3):75-81. doi:10.13582/j.cnki.1672-9102.2021.03.011

LIU H, LIU J Y. Fault Diagnosis of Power Transformer Based on Graph Convolutional Network [J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2021, 36(3):75-81. doi:10.13582/j.cnki.1672-9102.2021.03.011

基于图卷积神经网络的电力变压器故障诊断

刘华¹, 刘江永^{2*}

(1.湘潭市建筑设计院,湖南湘潭411100; 2.湘潭大学自动化与电子信息学院,湖南湘潭411105)

摘要:针对电力变压器故障多、诊断精确度低等问题,提出了一种基于图卷积神经网络(Graph Convolutional Network, GCN)电力变压器故障诊断的方法,该算法可以准确地识别电力变压器的故障类别,且实现了将数据结构转化成图结构.以电力变压器为实验对象,利用小波包变换(Wavelet Packet Transform, WPT)提取变压器油中特征气体数据特征,构建特征向量;接着利用马氏距离(Mahalanobis Distance, MD)来表示各个向量之间的相似度,以数据特征为顶点、相似度为边构建图结构;最后利用图卷积神经网络实现变压器的故障类别分类,准确识别出变压器故障类别,能够针对变压器故障部分进行检修.仿真实验表明:与深度信念网络(Deep Belief Network, DBN)和卷积神经网络(Convolutional Neural Networks, CNN)相比,本文提出的方法做出的诊断结果更加精确,综合诊断效果最好.

关键词:电力变压器;图卷积神经网络;故障诊断;小波包;马氏距离

中图分类号:TM411 **文献标志码:**A **文章编号:**1672-9102(2021)03-0075-07

Fault Diagnosis of Power Transformer Based on Graph Convolutional Network

LIU Hua¹, LIU Jiangyong²

(1. Xiangtan Architectural Design Institute, Xiangtan 411100, China;

2. School of Automation and Electronic Information, Xiangtan University, Xiangtan 411105, China)

Abstract: Aiming at the problems of many faults and low diagnosis accuracy of power transformer, a method of power transformer fault diagnosis was proposed, which based on graph convolutional network (GCN). The algorithm accurately identified the fault category of power transformer, and realized the transformation of data structure into graph structure. Taking the power transformer as the experimental object, wavelet packet transform (WPT) was used to extract the data features of characteristic gas in transformer oil and construct the feature vector; then, Mahalanobis distance (MD) was used to represent the similarity between vectors, and the graph structure was constructed with data feature as vertex and similarity as the edge; Finally, the graph convolution neural network was used to realize the transformer fault classification, which accurately identified the transformer fault category and repaired the fault part of the transformer. Simulation results show that, compare with deep belief network (DBN) and convolutional neural networks (CNN), the results of the new method are more accurate and the comprehensive diagnosis effect is the best.

Keywords: power transformer; graph convolutional network; fault diagnosis; wavelet packet; Mahalanobis distance

收稿日期:2021-03-12

基金项目:湖南省自然科学基金市州联合基金资助项目(S2021JJSSLH0022)

*通信作者, E-mail: 995781955@qq.com

变压器是电力系统的关键设备,其安全稳定的运行是电力系统可靠运行的重要保证,然而在变压器运行过程中,往往会出现各种故障隐患.为了保证电力系统运行的可靠性和稳定性,对变压器的故障进行诊断具有很大的实际意义^[1].电力变压器油中溶解的气体种类与它的绝缘故障类型有着密切的联系.在运行电压下,变压器油与固体绝缘材料会因为电热等故障慢慢发生劣化分解,并且油中会产生很少数量的各类低分子烃及 CO,CO₂ 等气体.故障类型的不同会导致产生气体的种类、含量、比例甚至产气速率均不相同^[2],可以利用变压器油中特征气体的相关数据诊断变压器故障类别,提高故障诊断的准确率^[3].

故障诊断的分离能力要求越来越高,能够准确快速地识别出电力变压器故障类别具有重要意义,故障诊断主要包括 3 个步骤:数据采集,特征提取,故障分类.目前,基于智能算法的故障诊断也越来越多.赵冬梅等^[4]提出基于改进堆栈自编码器的变压器故障诊断模型,通过仿真确定神经网络的结构,用无标签数据对网络进行无监督学习,提取变压器故障特征信息,最后输入有标签数据,通过反向传播算法对网络进行微调,实现对变压器故障分类,这种方法在一定程度上可提高诊断速度,但是存在未学习到的特征,网络的性能不足,且网络结构复杂,给诊断过程带来不便;文献[5]提出一种基于变分模态分解和堆叠稀疏自编码的齿轮故障诊断方法,但是这种方法容易存在特征丢失现象,不能将每个特征都计算在内.深度学习的运用可以在一定程度上提升故障诊断的速度和精度^[6-7],文献[8]提出基于深度学习的电力变压器智能故障诊断方法,利用混沌量子粒子群算法分别对堆叠自编码器和加权贝叶斯分类模型的参数进行优化,一定程度上提高了故障诊断的性能.为了能够设计一个精准的分类模型,本文引入了图卷积神经网络,这个深度学习网络随机初始化权重即可达到很高的分类精度^[9].但是图卷积神经网络带来了一个问题,它需要输入一个图结构,即需要寻找到样本数据之间的关系,由于马氏距离相比于其他算法可以有效地考虑到各种特征之间的关系,因此,本文选用马氏距离来计算不同样本之间的距离,从而找到它们之间的关系.在故障诊断过程中,小波变换等信号处理方法得到了有效的应用,但是小波变换只能对低频信号进行分解,而小波包变换作为小波变换的一种扩展,克服了小波无法分解高频故障的缺点,因此,本文采用小波包变换对采集到的数据进行预处理,有效地提取数据特征.

综上所述,本文提出了基于小波包变换、马氏距离、图卷积神经网络的变压器故障诊断方法.利用小波包变换和马氏距离对采集的样本数据进行预处理,构建图结构后,利用图卷积神经网络实现电力变压器的故障诊断,诊断出变压器故障类型.通过对电力变压器故障诊断,验证了所提方法的有效性.

1 小波包变换和马氏距离的简单介绍

1.1 小波包变换

小波包变换是对小波变换的一个改进,主要的算法思想:在小波变换的基础上,在每一级信号分解时,除了对低频子带进行进一步分解,也对高频子带进行进一步分解,最后通过最小化一个代价函数,计算出最优的信号分解路径,并以此分解路径对原始信号进行分解^[10-11].小波包变换的公式为

$$\begin{cases} d_i^{j,2n} = \sum_k h_{k-2l} d_k^{j-1,n}; \\ d_i^{j,2n+1} = \sum_k g_{k-2l} d_k^{j-1,n}. \end{cases} \tag{1}$$

式中: $d_i^{j,2n}, d_i^{j,2n+1}$ 为小波包分解系数; h_{k-2l}, g_{k-2l} 为小波包分解的低通和高通滤波器系数,小波包变换系数之和等于原始时域振动信号,从而得到归一化能量特征向量.

图 1 为小波包分解结构图.图 1 中原始信号分解为一个高频信号 2 和低频信号 0.由于在二进小波包变换中,各级小波包分解时,相邻级数的尺度函数和小波函数之间也具有递推关系,因此高频子带进一步分解成




图 1 小波包分解结构

高频 22 和低频 21,同时低频子带进一步分解为高频 02 和低频 00.同样,往后依次分解高频和低频.

1.2 马氏距离

马氏距离是一种距离的度量^[12-13],它是一种有效的计算 2 个未知样本集的相似度的方法.与欧氏距离不同,它能够考虑各种特性之间的联系.数据点 x, y 之间的马氏距离可以利用式(2)计算.

$$D_M(x, y) = \sqrt{(x - y)^T \Sigma^{-1} (x - y)}. \tag{2}$$

式中: Σ 为多维随机变量的协方差矩阵,如果协方差矩阵是单位向量,马氏距离就变成了欧氏距离.

2 图卷积神经网络的基本原理

GCN 实质是一个对象为图数据的特征提取器,GCN 在图上使用卷积运算,特征和消息在图网络中流动和传播,这个传播最原始形态就是状态的变化正比于图空间拉普拉斯算子作用在当前的状态.GCN 精妙地设计了一种从图数据中提取特征的方法,我们可以使用这些特征对图的数据进行节点分类、图分类、边预测和图的嵌入表示,因此 GCN 被广泛应用.

2.1 GCN 的结构

GCN 输入的是一张图,经过一层卷积层,对每个节点的邻居都进行一次卷积,并利用卷积的结果更新这个节点,然后经过激活函数,重复卷积-激活函数这个过程,直到达到预期的深度.最后,经过输出函数,将节点状态转换成相关的标签输出.此图中的每个节点无时无刻不因为邻居和更远的点的影响而在改变着自己的状态直到最终的平衡,关系越亲近的邻居影响越大.GCN 的具体结构如图 2 所示.

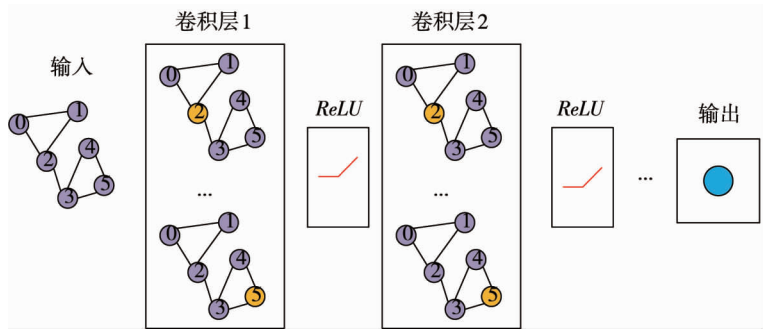


图 2 GCN 算法的传播结构

2.2 GCN 的传播方式

GCN^[14] 是一个神经网络层,假设一组数据有 N 个节点,每个节点都有自己的特征,这些节点的特征组成一个 $N \times D$ 维的矩阵 X ,各个节点之间的关系也会形成一个 $N \times N$ 维的矩阵 A ,也称为邻接矩阵. X 和 A 便是我们模型的输入.GCN 的层与层之间的传播方为

$$H^{(l+1)} = \sigma(\check{D}^{-\frac{1}{2}} \check{A} \check{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}). \tag{3}$$

式中: $\check{A} = A + I$, I 为单位矩阵; \check{D} 为 \check{A} 的度矩阵,公式为 $\check{D}_{ii} = \sum_j \check{A}_{ij}$; H 为每一层的特征,对于输入层, H 就是 X ; $W^{(l)}$ 为随机初始化权重; σ 为非线性激活函数.

GCN 用到拉普拉斯矩阵,其根据图谱理论实现拓扑图上的卷积操作,利用图的拉普拉斯矩阵的特征值和特征向量来研究图的性质^[9],在图上做傅立叶变换,并以拉普拉斯矩阵的特征向量作为傅立叶变换的基、特征值作为频率^[11].拉普拉斯矩阵的定义: $L = D - A$,其中 D 是度矩阵, A 是邻接矩阵.图 2 中拓扑图的几种矩阵如图 3 所示,假设有 6 个节点,若节点与节点之间的关系可以表示为图 3a 中的结构,那么它们的度矩阵、邻接矩阵和拉普拉斯矩阵为图 3b~图 3d 所示.




图 3 拓扑图的几种矩阵形式

3 GCN 在变压器故障诊断中的应用

3.1 变压器特征数据选取及诊断流程

针对变压器公开数据集,选取 400 个变压器特征数据,其中包括 100 个正常样本数据,贴上标签 0;100 个热故障样本,贴上标签 1;100 个低能放电样本,贴上标签 2;100 个高能放电样本,贴上标签 3.选取 H_2 , CH_4 , C_2H_2 和 C_2H_4 为故障特征量, H_2 含量主要用来判断低能放电, CH_4 和 C_2H_4 含量用来判断热故障, C_2H_2 含量用来判断高能放电.通过判断不同的气体浓度来判断变压器的故障类型.针对公开数据集,基于 GCN 变压器故障诊断流程如图 4 所示,具体步骤如下:

步骤 1:数据归一化.为了消除奇异样本数据导致的不良影响,对样本数据进行归一化处理;

步骤 2:利用小波包变换提取不同种类的数据特征,小波包变换通过对每一级信号进行信号分解,提取出特征,不同的特征用特征向量表示;

步骤 3:构建图结构.利用马氏距离计算不同的特征向量之间的相似度,以向量作为节点,相似度判断各节点之间的关系,构造出节点与节点之间的边,最后利用点与边构建图结构;

步骤 4:GCN 实现变压器故障诊断.将步骤 3 中的结果转化成邻接矩阵和度矩阵的表示方式,输入到 GCN 中,实现电力变压器故障诊断.判断 GCN 输出是否收敛,若收敛,则结束迭代过程;若不收敛,则继续迭代.

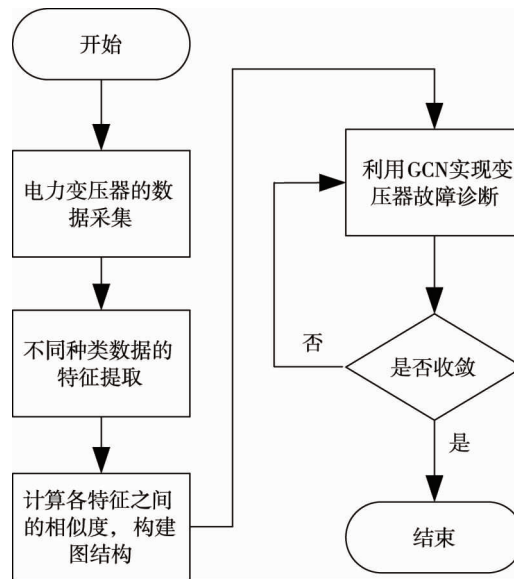


图 4 基于 GCN 的变压器故障诊断流程

3.2 实验分析

小波包变换提取变压器特征后,采用马氏距离来计算各个未知样本集的相似度.将每个特征作为不同的数据点 x 和 y ,利用式(2)计算协方差,从而得到不同特征点之间的相似度,得到不同的距离,距离越小,相似度就越大,反之,距离越大,相似度就越小.通过多次实验验证,马氏距离的阈值为 0.3 时,能够尽可能使得多数特征向量之间都存在关系,即当任意 2 个特征向量之间的距离小于 0.3 时,这 2 个特征向量可定义为存在一定的关系.利用特征向量之间的关系构建拓扑图结构,以每个特征向量为节点,特征向量之间的关系为边构建拓扑结构.图 5 为 4 种不同状态下的特征向量构建的拓扑图.

GCN 网络深度的选取,文献[14]有关 GCN 网络层数选取相关介绍,文中通过实验验证网络层数并不是越深效果越好.因此,本文分别对两层网络、三层网络、四层网络进行实验,实验结果如图 6~图 8 所示.图 6 显示,两层网络可以将 4 种故障分开,正常状态和低能放电部分出现少数交叉,但相比于图 7 和图 8,图 6 出现的交叉部分最少,表明两层网络可以更有效地分离不同类型的故障,因此,在实际工业中,使用两层 GCN 网络诊断电力变压器故障更加准确.




图 5 4 种不同状态下的特征向量构建的拓扑图




图 6 两层 GCN 网络分类效果




图 7 三层 GCN 网络分类效果




图 8 四层 GCN 网络分类效果

4 对比实验分析

上述通过实验验证了 GCN 算法对变压器故障诊断效果,为了更好地证明 GCN 算法的有效性,我们将 GCN 与几种先进的算法进行了对比,对比结果如表 1 所示。

深度信念网络(DBN)^[15]:将若干个受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)“串联”起来则构成了一个 DBN,其中,上一个 RBM 的隐层即为下一个 RBM 的显层,上一个 RBM 的输出即为下一个 RBM 的输入.DBN 在训练过程中先训练每一层 RBM 网络,在最后一层设置反向传播(Back Propagation, BP)网络,RBM 的输出特征向量作为 BP 的输入,将贴有标签的变压器的样本数据作为输入,训练 DBN 网

网络,随机抽取 1/4 的样本作为测试集,计算出相应的结果.为了保证对比实验的可靠性,选取两层 DBN 网络;训练集设 100×4 个样本;测试集设 20×4 个样本;迭代次数设为 40;学习率设为 0.01.

卷积神经网络(CNN)^[16]:CNN 模型主要由输入层、隐含层(卷积层和池化层)、全连接层和输出层组成,在模型中卷积层和池化层会交替出现.实验中设置两层卷积层-池化层网络;输入 100×4 个样本,随机选取 20×4 个样本输入到训练后的模型中做测试,计算出分类精确度、损失率等结果.同样,为了保证对比实验具有说服力,选取两层 CNN 网络;训练集设 100×4 个样本;测试集设 20×4 个样本;迭代次数设为 40;学习率设为 0.01.

表 1 中分别记录了他们的损失率、标准误差、平均绝对误差和精确度,4 组实验后取其平均值.可以看出,GCN 的平均损失率为 0.028 7,比 DBN 和 CNN 小很多.本文所提算法的诊断精确度最高,在第 2 次和第 3 次实验时,利用本文所提方法的诊断精确度可达到 100%,平均精确度为 99.7%,而 DBN 和 CNN 的诊断精确度分别为 90.0%,97.4%,均没有 GCN 的诊断精确度高,与此同时,表 1 显示,GCN 的诊断误差最小.综上所述,GCN 算法在故障诊断上的应用效果非常好,大大提高了故障诊断的精确度.

表 1 不同算法的对比结果

	算法	损失率	标准误差	平均绝对误差	精确度
f_0	DBN	0.070 2	0.155 2	0.121 1	0.884
	CNN	0.040 1	0.112 4	0.095 2	0.973
	GCN	0.036 3	0.097 5	0.052 8	0.996
f_1	DBN	0.063 2	0.143 2	0.132 1	0.901
	CNN	0.052 4	0.112 2	0.099 7	0.962
	GCN	0.022 8	0.106 4	0.062 5	1.000
f_2	DBN	0.070 2	0.132 1	0.110 0	0.910
	CNN	0.053 4	0.120 0	0.102 1	0.981
	GCN	0.023 4	0.092 1	0.056 4	0.990
f_3	DBN	0.060 1	0.112 3	0.106 5	0.904
	CNN	0.043 4	0.102 4	0.102 3	0.980
	GCN	0.032 3	0.097 5	0.075 2	1.000
平均值	DBN	0.065 9	0.135 7	0.117 4	0.900
	CNN	0.047 3	0.111 8	0.099 8	0.974
	GCN	0.028 7	0.098 4	0.061 7	0.997

5 结论

1) 将数据结构转化成了图结构.首先利用小波包变换提取故障数据的特征;然后利用马氏距离计算特征向量之间的相似度,利用相似度构建点和边之间的关系,从而得到拓扑结构.不同的数据预处理方法对诊断的结果可能存在一定的影响,本文所使用的小波包预处理方法具有敏感度高的优点.

2) 利用 GCN 实现电力变压器的故障诊断.将拓扑图输入到卷积神经网络中,实验验证了两层网络的效果最好,有效将变压器的不同故障分开,实现了电力变压器故障诊断,并验证了诊断效率.

3) 仅对变压器进行了故障类型判断,实现故障分类.而故障恢复也是故障诊断中的一个重要环节,需要更多的学者深入研究.

参考文献:

- [1] 廖伟涵,郭创新,金宇,等.基于四阶段预处理与 GBDT 的油浸式变压器故障诊断方法[J].电网技术,2019,43(6): 2195-2203.
- [2] 刘一,倪远平.三比值灰关联度分析的变压器故障诊断法[J].高电压技术,2002(10):16-17.
- [3] Xu Y Y, Li Y, Wang Y J, et al. Integrated decision-making method for power transformer fault diagnosis via rough set and DS

evidence theories[J]. IET Generation, Transmission & Distribution, 2020, 14(24): 5774–5781.

- [4] 赵冬梅, 王闯, 马泰屹. 基于改进堆栈自编码器的变压器故障诊断模型[J]. 华北电力大学学报(自然科学版), 2020, 47(6): 61–67.
- [5] 徐飞, 蒋占四, 黄惠中. 基于 VMD-样本熵和 SSAE 的齿轮故障诊断[J]. 组合机床与自动化加工技术, 2020(8): 39–42.
- [6] Zhu L, Rao W, Qiao J, et al. Diagnosing and classifying the fault of transformer with deep belief network[C]// International Conference on Data Science, 2020: 550–560.
- [7] Li Y, Yu F, Cai Q, et al. Image fusion of fault detection in power system based on deep learning[J]. Cluster Computing, 2019, 22: 9435–9443.
- [8] 张朝龙, 何怡刚, 杜博伦, 等. 基于深度学习的电力变压器智能故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(1): 81–89.
- [9] Bruna J, Zaremba W, Szlam A, et al. Spectral networks and locally connected networks on graphs[J]. Computer Science, 2013: 17682909.
- [10] 高升, 吴亦农, 蒋珍华. 基于小波包变换和支持向量机的制冷机动静碰摩故障部位识别研究[J]. 红外与毫米波学报, 2019, 38(5): 627–632.
- [11] Lotfollahi-Yaghin M A, Koohdaragh M. Examining the function of wavelet packet transform (WPT) and continues wavelet transform (CWT) in recognizing the crack specification[J]. KSCE Journal of Civil Engineering, 2011, 15(3): 497–506.
- [12] 吴香华, 牛生杰, 吴诚鸥, 等. 马氏距离聚类分析中协方差矩阵估算的改进[J]. 数理统计与管理, 2011, 30(2): 240–245.
- [13] 秦庆强, 张晓安, 李艾华, 等. 马氏距离在模拟电路硬故障检测中的应用研究[J]. 电子测量与仪器学报, 2009, 23(7): 41–45.
- [14] Zhang H, Lu G, Zhan M, et al. Semi-Supervised Classification of Graph Convolutional Networks with Laplacian Rank Constraints[J]. Neural Processing Letters, 2021(11): 1–12.
- [15] Zhang X T, Pan X G, Wang S T. Fuzzy DBN with rule-based knowledge representation and high interpretability[C]//2017 12th International Conference on Intelligent Systems and Knowledge Engineering (ISKE). Nanjing, 2017: 1–7.
- [16] Pattanayak S. Convolutional neural networks[M]. Berkeley: Pro Deep Learning with TensorFlow, 2017: 153–221.