

基于双输入残差图卷积网络的电力变压器健康状态评估方法*

李文悦 何怡刚 邢致恺 周亚中 雷蕾潇

(武汉大学电气与自动化学院 武汉 430072)

摘要: 电力变压器运行过程中故障数据远少于正常数据,数据不平衡问题较为严重,并且监测变量间耦合关系复杂,导致状态评估任务的建模难度大、评估精度低。针对相关问题,提出基于双输入残差图卷积网络的电力变压器健康状态评估方法。首先,采用 SMOTE Tomek 混合采样算法对训练数据进行不平衡数据预处理,解决了故障数据过少、训练数据严重不平衡的问题;然后,考虑到单一度量无法准确描述变量间相关性的问题,提出多度量融合构图方法,通过多个度量方法共同学习变量间的相关性,并构造图结构数据;最后,提出基于切比雪夫图卷积的双输入残差图卷积网络,对所构造的图结构数据进行特征提取,并通过自注意力机制进行特征融合,得到变压器的状态评估结果。在真实电力变压器运行的油中溶解气体及油化试验数据集上进行了对比实验,实验结果表明,所提出方法的状态评估准确率达到 94.7%,F1 分数达到 0.942,高于其他深度学习方法,具有最佳的评估性能。

关键词: 电力变压器;状态评估;图卷积网络;图池化;数据不平衡

中图分类号: TN919.5;TM407

文献标识码: A

国家标准学科分类代码: 470.40

Health evaluation of power transformer based on double input residual graph convolutional network

Li Wenyue He Yigang Xing Zhikai Zhou Yazhong Lei Leixiao

(School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China)

Abstract: The operation of power transformers involves significantly fewer fault data compared to normal data, resulting in a severe data imbalance issue. Additionally, the complex coupling relationships among the monitored variables make the modeling of condition assessment tasks challenging and lead to low evaluation accuracy. Aiming at the related problems, a power transformer health condition evaluation method based on double input residual graph convolutional network is proposed. First, SMOTE Tomek mixed sampling algorithm was used to pre-process the unbalanced data of the training data, which solved the problem of insufficient fault data and difficult classification. Then, a multi-metric fusion graph construction method is proposed to learn the correlation between variables from multiple variables and construct the graph structure data. Finally, a double input residual graph convolutional network (DI-ResGCN) based on the ChebyNet is proposed, feature extraction is carried out on the constructed graph structure data, and feature fusion is carried out through the self-attention mechanism to obtain the transformer health evaluation results. Experiments were carried out on a dataset of dissolved gases in oil and oil test collected by a real power transformer, and experimental results show that the proposed method has a state assessment accuracy of 94.7% and F1 score of 0.942, outperforming other deep learning methods and exhibiting the best evaluation performance.

Keywords: power transformer; health evaluation; graph convolutional network; graph pooling; data imbalance

0 引言

变压器作为现代电网的核心装备,在电能输送、电压转换等任务中发挥着重要的作用,其安全稳定运行对电网的可靠性和稳定性至关重要。变压器的运行工况较为复杂,一旦发生故障,将影响电力系统正常运行,甚至造成严重的经济损失^[1-2]。因此,对变压器进行运行状态监测对保障电网的安全稳定、减少设备损坏具有重要意义。

变压器状态监测方法主要可以分为离线预防性监测和在线监测方法^[3]。离线监测方法包括电气试验如局部放电等,但是这类方法存在一定的滞后性,且易造成区域短时停电^[4]。在线监测方法主要针对振动数据、油中溶解气体分析(dissolved gas analysis, DGA)等进行研究,包括基于模糊理论的方法以及机器学习算法如支持向量机^[5-7](support vector machine, SVM)等。文献[8]融合模糊 K 近邻及证据理论,推理得出绝缘状态的置信分布式结果,能够准确评估变压器油纸的绝缘状态;文献[9]通过多尺度标准差模糊熵和哈里斯鹰算法优化 SVM 的参数,实现了更高精度的变压器故障识别。文献[10]通过频域介电谱提取特征参量,基于 SVM 构建变压器油浸纸绝缘老化分类模型。但是,这类方法的拟合能力往往较为有限,导致模型性能不佳。

近年来,基于深度学习的方法由于其在提取深度特征表示等方面的突出优势,已广泛应用至状态评估领域中^[11]。文献[12]采用回波状态网络解决样本不平衡问题,并通过改进的深度残差收缩网络提取特征,实现高精度变压器状态评估。文献[13]利用最大相关最小冗余方法筛选风力发电 SCADA 数据,提取相关特征变量,然后基于门控循环单元建立状态评估模型,通过预测功率与实际功率间的残差评估机组的运行状态。文献[14]采用完全自适应噪声集合经验模态分解将油中溶解气体分解为子序列,然后基于门控循环网络和麻雀搜索算法优化 SVM 构建预测模型,提高了溶解气体预测的精度。以上研究分别取得了一定进展,然而,基于深度学习的模型必须以规则的欧式数据作为输入,而当变压器运行状态发生异常时,多种监测数据相互影响,同时发生变化,具有时变性、非线性等特点,这些方法在变量相关性挖掘上尚有不足^[15]。

图神经网络以非欧式数据作为输入,能够更好的建模现实生活中数据间的相关关系,已经在社交网络^[16]、自然语言处理^[17]、交通预测^[18]等领域得到了广泛应用,同样也在设备状态监测领域取得了不错的进展。文献[19]依据风电机组的物理结构进一步将其划分为多个子图,并利用图注意力机制和多头注意力机制深入挖掘关联性,构建动态图神经网络模块提取时空关联特征,

实现风电机组的在线异常检测。文献[20]通过构建相关、因果以及专家经验 3 种知识矩阵,将专家经验融合至智能算法中,提升了图网络模型的泛化性能和可解释性。文献[21]通过时间卷积网络提取时间特征,通过图卷积网络学习溶解气体之间的相关性,对变压器油中溶解气体进行预测。图作为由节点和边组成的不规则数据,能够更充分的表示现实世界中多种数据的耦合关系。

随着变压器运行环境的变化,油中溶解气体以及其他监测数据之间会分解、合成等相互影响,因此,挖掘多变量数据相关性对提高模型性能至关重要。基于以上分析,对电力变压器运行监测数据进行图结构建模,充分挖掘数据空间关联性,提出了一种基于图卷积网络和图池化层的状态监测方案。首先,采用 SMOTE Tomek 混合采样算法对训练数据进行平衡预处理,然后采用多度量融合构图方法构建多个监测变量的 k 近邻图,之后将其输入至残差图卷积网络进行特征提取,并通过自注意力机制进行特征融合,最终得到变压器的状态评估结果。实验结果表明,相较于其他深度学习算法,所提出的方法在状态评估任务中取得了最佳的分类性能。

1 算法基本原理

1.1 图卷积神经网络

根据卷积构建思路的不同,图卷积神经网络可以分为基于谱域的图卷积网络和基于空间域的图卷积网络。基于空间域的图卷积神经网络的核心思想是利用聚合函数聚合节点特征,采用消息传播机制,通过边传播节点信息。而基于谱域的图卷积以图傅里叶变换为基础,在谱域内进行卷积,具有坚实的理论基础。

在图谱理论中,对称的归一化拉普拉斯矩阵定义为:

$$\mathbf{L} = \mathbf{I}_n - \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \quad (1)$$

式中: $\mathbf{D}$ 为图 G 的度矩阵, $\mathbf{A}$ 为图 G 的邻接矩阵, $\mathbf{I}_n$ 为 n 阶单位矩阵。

傅里叶变换及其逆变换定义为:

$$F(\omega) = \varphi(\omega) = \int f(x) \exp(-i\omega x) dx \quad (2)$$

$$f(x) = \varphi^{-1}(F(\omega)) \quad (3)$$

式中: φ 为傅里叶变换。

对拉普拉斯矩阵进行特征值分解 $\mathbf{L} = \mathbf{U} \mathbf{\Lambda} \mathbf{U}^{-1} = \mathbf{U} \mathbf{\Lambda} \mathbf{U}^T$,其中 $\mathbf{U}$ 为由特征向量组成的向量矩阵, $\mathbf{\Lambda}$ 为特征值为对角元素的矩阵。然后将传统傅里叶变换的基 $\exp(-i\omega x)$ 替换为 $\mathbf{U}^T$,因此 y 的图傅里叶变换可以定义为 $\hat{y} = \mathbf{U}^T y$,图傅里叶逆变换定义为 $y = \mathbf{U} \hat{y}$ 。

卷积定理的逆变换表示为:

$$f \times g = \varphi^{-1}(\varphi(f) \cdot \varphi(g)) \quad (4)$$

利用图傅里叶变换和图傅里叶逆变换,可以得到图

卷积的最终形式:

$$f \times g = U(U^T f \cdot U^T g) \quad (5)$$

将 $U^T g$ 写作 g_θ ,即以 θ 为参数的卷积核,基于谱域的图卷积可以被定义为:

$$f \times g = U g_\theta U^T f \quad (6)$$

但是,该方法具有复杂度高、不具局部性等问题,文献[22]采用切比雪夫多项式来拟合卷积核 θ ,大大减小了计算开销,切比雪夫多项式的递推关系为:

$$T_0(L) = 1, T_1 = L, T_{n+1}(L) = 2LT_n(L) - T_{n-1}(L) \quad (7)$$

因此,基于谱域的图卷积可以被表示为:

$$g_\theta(A) = \sum_{k=0}^{K-1} \beta_k T_k(\tilde{A}), \tilde{A} = \frac{2A}{\lambda_{\max}} \quad (8)$$

式中: β_k 为切比雪夫多项式的系数, A 为以拉普拉斯矩阵 L 的特征值为对角元素的矩阵, $\lambda_{\max}$ 为特征值的最大值。切比雪夫图卷积可以被表示为:

$$f \times g = U g_\theta U^T f = \sum_{k=0}^{K-1} \beta_k T_k(\tilde{A}) f \quad (9)$$

切比雪夫图卷积网络相较于其他图卷积模型具有最佳的综合性能^[23]。因此,模型中采用的图卷积网络为三阶切比雪夫图卷积。

1.2 基于边收缩的图池化方法

图池化方法可以有效降低特征图的维度,扩大接受域,从而帮助模型获得更好的性能及泛化性。EdgePool 是由文献[24]提出的一种基于边收缩的池化机制,它能够学习局部、稀疏的硬池化变换。通过选择边以及汇集边所连接的节点,EdgePool 能够自然地考虑到图结构,并

且确保不会完全删除节点。

在 EdgePool 中,它迭代地对每个边对上的节点进行合并,形成一个新节点,并保留合并后的节点与新节点的连接关系。实现 EdgePool 的流程如图 1 所示,其具体实现方法如下:

1) 计算边及节点分数。根据节点特征计算每条边的原始分数,其计算方法如式(10)所示。

$$r(e_{ij}) = P(n_i || n_j) + b \quad (10)$$

式中: n_i 和 n_j 为节点 i 和节点 j 的节点特征, P 和 b 为可学习参数。在图 1 中,为了方便表示,每两个节点间的双向边原始分数相同。然后,计算每条边的 $\exp(r)$ 作为边的分数,并且计算每个节点的所有入边的分数之和作为该节点的分数。

2) 边分数归一化。对于同一节点的若干条入边,通过 Softmax 函数对其进行归一化处理,得到边的最终分数。

3) 边收缩。选择图中分数最大的一条边进行聚合,将该边两端的节点合并为一个新的节点,然后在与原合并节点相邻的边之外,继续选择最大的边进行迭代收缩,直至没有未参与聚合的节点。因此,最终聚合的节点约为总节点的 50%。合并对应的节点之后,新的节点的特征由被合并的两个节点特征加权,同时考虑原始边的分数,超节点的特征计算如式(11)所示。

$$\hat{n}_{ij} = \max(s_{ij}, s_{ji}) (n_i + n_j) \quad (11)$$

EdgePool 既可独立应用于节点分类任务,又可集成至已有的图网络模型中,能够减少节点数量,降低计算需求,提高模型性能。




图 1 EdgePool 池化过程
Fig. 1 Pooling process of EdgePool

2 变压器状态评估方法

随着电力变压器运行环境和运行状态的变化,其监测指标也会发生变化,例如当油温升高时,烷烃会分解产生烯烃和炔烃,不同的油中溶解气体含量之间具有较强的相关性。因此,基于图深度学习充分挖掘变压器监测数据空间关联性,建立电力变压器状态评估模型。

2.1 基于 SMOTE Tomek 混合采样算法的不平衡数据处理方法

实际工业应用中,故障数据量远小于正常运行的数据量,在数据不平衡的情况下,对变压器的建模及状态监测难度更大。为解决训练数据严重不平衡的问题,采用 SMOTE Tomek 混合采样算法进行数据预处理,使得训练数据实现类平衡,提高模型的性能。

SMOTE Tomek 混合采样算法示意图如图 2 所示,由

合成少数类过采样技术 (synthetic minority oversampling technique, SMOTE) 算法和 Tomek Link 算法组成。SMOTE 算法的主要思想是对少数类人工合成新的样本以扩充少数类样本数。SMOTE 算法的具体步骤为:

1) 在少数类中随机选择部分样本 x , 计算它到少数类样本集中其他样本的欧式距离, 并得到其 k 近邻。

2) 在 k 近邻中随机选择若干个样本 x_n 。对于随机选出的近邻样本 x_n , 按照如式 (12) 所示构建新的样本, 并添加到少数类样本中。




图 2 SMOTE Tomek 混合采样算法

Fig. 2 SMOTE Tomek mixed sampling algorithm

经 SMOTE Tomek 混合采样算法对训练数据进行预处理后, 多个类别样本数量达到平衡, 并且保障了扩充样本的数据质量。

2.2 基于多度量融合的图构造方法

图作为一种非欧几里得数据, 由节点和边组成, 可以被表示为 $G=(V, E)$, 其中, G 代表图, V 代表节点, E 代表连接节点的边。对于变压器运行过程中的多种监测特征量, 随着变压器运行状态的变化, 其多个监测变量相互影响, 因此, 将每个监测变量视作一个节点, 将变量之间的相互关系视作带有权重的边, 将每个样本构造为一个图。

构造能够准确描述变量潜在相关性的图对模型性能至关重要, 而不同的度量所关注的重点及计算方式各有不同, 采用单一度量可能导致计算结果不准确, 进而影响模型性能。因此, 提出基于多度量融合的构图方法。对于每两个节点之间的边权重, 分别通过高斯核函数、余弦相似度以及皮尔逊相关系数进行计算。其中, 高斯核函数通过将向量投影到高位空间来度量向量间的相似性; 余弦相似度用来衡量样本向量之间的差异, 其绝对值越大则样本间的相关性越强; 皮尔逊相关系数用于衡量两个样本间的线性关系。节点间的高斯核函数、余弦相似度以及皮尔逊相关系数的计算公式分别如式 (13) 所示。

$$A_{ij}^{Gaus} = \exp\left(-\frac{\|(\mathbf{x}_i, \mathbf{x}_j)\|^2}{2\xi^2}\right), \mathbf{x}_j \in Ne(\mathbf{x}_i) \quad (13)$$

其中, ξ 是高斯核的带宽。

$$A_{ij}^{Cos} = 1 - \frac{\mathbf{x}_i - \mathbf{x}_j^T}{\|\mathbf{x}_i\| \|\mathbf{x}_j\|} \quad (14)$$

$$x_{new} = x + rand(0, 1) \times |x - x_n| \quad (12)$$

经过采样后, 不同类别样本量达到平衡状态, 但生成的部分数据质量较低, 易出现新增样本类别模糊等问题。因此, 采用 Tomek Link 算法进行欠采样, 用于去除不同类别之间的重叠部分和噪声, 其具体步骤为:

1) 对于多数类别, 通过欧氏距离计算每个样本的最近邻, 并判断每对样本的类别标签是否相同。

2) 对于类别不同的样本, 建立一个 Tomek Link 对, 并将其标记为噪声, 从数据集中移除。

$$A_{ij}^{Pear} = \frac{\sum_{t \in T} (\mathbf{x}_{i,t} - \bar{\mathbf{x}}_i) (\mathbf{x}_{j,t} - \bar{\mathbf{x}}_j)}{\sqrt{\sum_{t \in T} (\mathbf{x}_{i,t} - \bar{\mathbf{x}}_i)^2} \sqrt{\sum_{t \in T} (\mathbf{x}_{j,t} - \bar{\mathbf{x}}_j)^2}} \quad (15)$$

然后, 将计算得到的 3 种相关性矩阵的绝对值相加并计算均值, 作为最终的邻接矩阵, 其计算公式如式 (16) 所示。

$$A_{ij} = \frac{(|A_{ij}^{Gaus}| + |A_{ij}^{Cos}| + |A_{ij}^{Pear}|)}{3} \quad (16)$$

2.3 双输入残差图卷积网络

本方法所采用的特征提取模型如图 3 所示, 考虑到油中溶解气体数据间具有更大的相关性, 而油化试验指标间的耦合关系则与之不同, 因此将数据分为两组, 分别对其通过多度量融合方法进行图构造, 而后分别输入至残差图卷积网络中。所提出的残差图卷积网络由 3 个堆叠的特征提取模块组成, 每个特征提取模块由图卷积层 (graph convolutional network, GConv)、批处理层、ReLU 激活函数组成, 并输入至 EdgePool 层进行图池化, 单个特征提取模块的输出可以被表示为:

$$X^{output} = EdgePool(ReLu(GConv(AXW))) \quad (17)$$

式中: A 为多度量融合方法所构造的邻接矩阵, X 为输入, W 为可训练的权重矩阵。

由于图卷积网络层数较深时, 容易导致对不同的簇重复应用拉普拉斯平滑, 从而造成分类性能下降, 因此对模型添加残差连接。经特征提取后, 将两种不同数据所提取的特征进行拼接, 考虑到不同类型数据所提取的特征对模型分类的重要性不同, 通过自注意力机制对其进行特征加权融合, 然后输入至全连接层中并通过 Softmax 函数进行分类, 得到最终的状态评估结果。




图 3 双输入残差图卷积网络

Fig. 3 Two-input residuals graph convolution network

2.4 变压器状态评估流程

提出的变压器状态评估模型主要包括数据预处理、图构造、特征提取和状态评估 4 个阶段,其总体框架如图 4 所示,具体的状态评估过程如下:

- 1) 数据预处理。在划分好训练集和验证集后,采用 SMOTE Tomek 混合采样算法将训练集数据进行少数样本扩充以解决样本不平衡的问题。然后将所采用的数据分为油中溶解气体和油化试验数据两组,并对其进行最大最小归一化处理。
- 2) 图构造。采用多度量融合构图方法分别对两类数据构造 k 近邻图,学习变量间的相关性。
- 3) 特征提取。将所构造的图结构数据输入至双输入残差图卷积网络中,经图卷积层及图池化层提取两类数据的特征,并通过自注意力机制进行特征融合。
- 4) 状态评估。所提取的特征经全连接层及 Softmax 函数后输出变压器状态评估的结果。

3 实验验证

3.1 数据描述与处理

为了验证所提出的变压器状态评估方法的有效性和优越性,采用参考文献[12]所使用的变压器监测数据进行实验,其具体包含 3 个来源,共计 377 个案例。第 1 个数据集来自于参考文献[25],共 14 个案例。第 2 个数据集收集了一个武汉变电站的 12 台变压器的监测数据,共




图 4 变压器状态评估框架

Fig. 4 Transformer condition evaluation framework

335 个案例。第 3 个数据集来自于《电网设备状态检测技术应用典型案例:2011-2013 年》^[26],共 28 个案例。根据健康指数的大小,将数据集样本分为 5 种运行状态,分别为非常好、好、中度、差和非常差。本数据集的健康状态类别数量如表 1 所示,可以看出本数据集存在较严重的不平衡问题,差和非常差的样本数量较少,这会

导致状态评估的难度进一步加大。

本实验所采用的变量共 9 种,分别包括 5 种油中溶解气体数据: H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 ,以及 4 种油化试验数据:油中微水含量、酸度、糠醛含量、击穿电压。考虑到油中溶解气体由绝缘油裂解产生,其变量间相关性相较于其他油化试验数据更大,因此在本实验中,将数据分

为两组分别进行特征提取。本实验中由油中溶解气体数据和油化试验数据所构造的 k 近邻图的 k 值分别设置为 4 和 3。

表 1 数据集各类别样本数量

Table 1 The number of each classes in the dataset

状态	样本数量
非常好	121
好	98
中等	85
较差	48
非常差	25

在实验验证中,将数据集按照 70% 和 30% 的比例随机划分为训练集和测试集,并进行最大最小归一化处理。之后,将划分好的训练集采用 SMOTE Tomek 混合采样算法进行平衡预处理。最后,对经数据预处理后的训练集及测试集构造 k 近邻图,以作为模型的输入。本实验采用 5 折交叉验证,实验结果为 5 次实验的均值。

3.2 实验设置与评价指标

该模型基于 Pytorch Geometric 库实现,迭代训练 300 个 epoch;初始学习率设置为 0.01,每 10 个 epoch 的衰减速率为 0.5,实验中使用 SGD 优化器进行优化。图卷积的阶数为 3,即切比雪夫图卷积。

实验中采用分类任务中两个常见的指标来验证所提出模型的性能,分别为准确率 (accuracy) 和 F1 分数 (F1-score),其计算公式如式 (16) ~ (17) 所示。由于测试集数据存在较为严重的不平衡问题,F1-score 能够较好地反映模型的整体分类性能。

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

(18)

$$F1 - score = \frac{2(Precision \times Recall)}{Precision + Recall}$$

(19)

式中: TP 、 TN 、 FP 、 FN 分别为真正例、真反例、假正例、假反例, $Precision$ 为精确率, $Recall$ 为召回率。

3.3 实验结果分析

1) 特征提取单元数讨论

提出的模型主要通过多个基于图卷积层的特征提取单元进行特征提取,因此,为了探讨特征提取单元数量对模型性能的影响,本节设计了层数从 1~5 多个不同模型,分别进行实验,通过比较准确率与 F1 分数,验证最优模型结构。

图 5 展示了不同个数特征提取单元的状态评估性能指标,通过对比不同模型的准确率与 F1 分数可以看出,当单元数为 3 时,模型性能达到最优,而模型过深会导致性能大幅下降,因此,所采用的模型为 3 个特征提取单元。




图 5 不同特征提取单元数量的模型性能

Fig. 5 Model performance with different number of feature extraction units

2) 构图方法对比

为了验证多度量融合构图方法的有效性,针对所采用的 3 种度量方法,分别通过单独使用一种度量、融合两种度量以及融合 3 种度量方式构图,并进行状态评估实验,比较其状态评估的准确率以及 F1 分数,实验结果如表 2 所示。

从表 2 可以看出,单个度量构图的性能相对来讲是最差的,这是因为单个度量难以全面的描述变量间的相关关系,而构造真实精确的相关性图是保障模型性能的前提。采用两个度量融合构图时,模型性能有一定提高,所提出的多度量融合构图的模型准确率最高,证明多个度量间能够相互弥补,提高分类能力。

表 2 不同构图方式的对比实验结果

Table 2 Results of different graph construction method

构图方法	Accuracy	F1-score
Gaus	0.907	0.902
Cos	0.889	0.895
Pear	0.858	0.861
Gaus+Cos	0.926	0.928
Gaus+Pear	0.917	0.914
Cos+Pear	0.928	0.933
Gaus+Cos+pear	0.947	0.942

3) 状态评估性能对比

为了验证所提出双输入残差图卷积模型的性能,本节采用 4 种经典的深度学习方法作为对比模型,分别为卷积-门控循环神经网络 (CNN-GRU)、全连接网络 (FCNN)、长短时记忆网络 (LSTM) 以及图注意力网络 (GAT),并分别进行变压器状态评估实验。

表 3 展示了 5 种模型的状态评估结果。根据表 3 可以看出,所提出的方法在准确率和 F1 分数两个指标皆优于对比方法,即具有更佳的状态评估性能。LSTM 模型的优势在于捕捉长期依赖关系,对数据的变量相关性挖掘不足,因此性能较差。CNN-GRU 模型同时关注变量间的


相关性以及时序特征,其性能优于其他对比模型,这也证明了挖掘变量耦合关系对模型性能的重要性。另外,与 GAT 模型的对比实验结果也证明了所提出方法在图结构数据特征提取方面的优越性。

表 3 状态评估对比实验结果


Table 3 Health evaluation experimental results		
模型	Accuracy	F1-score
CNN-GRU	0.917	0.916
FCNN	0.909	0.915
LSTM	0.894	0.901
GAT	0.902	0.912
DI-ResGCN	0.947	0.942

此外,为了进一步验证本方法的特征提取能力,对上述模型所提出的特征进行了可视化对比。 t 分布随机邻域嵌入算法 (t-distributed stochastic neighbor embedding, t -SNE) 是一种常用的降维技术,能够将高维空间的数据映射到二维或三维的低维空间中。图 6 展示了 5 种模型的 t -SNE 可视化特征图。


根据图 6 可以看出,所提出方法的不同类特征分界更为明显,重叠部分更少,并且类间距离较大,而其他方法所提取的特征存在不同类别重叠、类间距离较小的问题,证明所提出的方法具有更好的特征提取能力。



(c) 长短时记忆神经网络
(c) LSTM



(d) 图注意力网络
(d) GAT




(e) 双输入残差图卷积网络
(e) DI-ResGCN

图 6 t -SNE 可视化特征图
Fig. 6 t -SNE visual feature map


另外,由于所提出的方法相较于其他对比模型更为复杂,参数量更多,其需要的训练成本如计算时间也更大,但是考虑到所提出的方法状态评估能力明显优于其他方法,所以计算时间是可以接受的。

4) 消融实验

为了验证所提出方法的各个模块的有效性,基于最终构造的双输入残差图卷积模型,分别构造了 3 个衍生



(a) 卷积-门控循环神经网络
(a) CNN-GRU



(b) 全连接网络
(b) FCNN

对比模型,Model1 为不采用 SMOTE Tomek 混合采样算法,即使用原始数据进行训练的方法;模型 2 为无残差连接的方法;Model3 为采用单输入的方法,即将 9 个变量构造为 1 张图。以相同的流程分别对 3 个对比模型进行了状态评估,表 4 为状态评估的结果。

从表 4 可以看出,采用数据平衡预处理、残差连接均对模型分类能力有较大提升。通过 SMOTE Tomek 混合采样方法对训练数据进行预处理,在保证数据质量的前提下解决了故障数据过少的问题。对模型添加残差连接能够避免因为网络层数较深导致分类性能下降的问题。另外,将数据按照是否为油中溶解气体来分开进行图构造和特征提取,同样提高了模型的性能。

表 4 状态评估对比实验结果
Table 4 Health evaluation compared experimental results

模型	Accuracy	F1-score
Model1	0.914	0.917
Model2	0.909	0.912
Model2	0.921	0.922
DI-ResGCN	0.947	0.942

4 结 论

本文为提高电力变压器状态评估的准确率,克服现有算法在监测变量相关性提取上的不足,保障电网安全稳定运行,提出了一种基于双输入残差图卷积网络的状态评估算法。首先,通过 SMOTE Tomek 混合采样算法对训练数据进行过采样及降采样处理,实现各类数据样本数平衡,在保障数据质量的前提下解决了数据不平衡问题。然后,融合高斯核函数、余弦相似度以及皮尔逊相关系数 3 种度量方式对监测变量的相似性以及相关性进行计算,弥补了单一度量方式在计算相关性上的不足。最后基于图卷积网络与边收缩池化方法构造双输入残差图卷积模型,并对变压器油中溶解气体及油化试验数据进行特征提取和状态评估。通过实验验证可知,与其他深度学习方法相比,该方法的特征提取能力和状态评估能力最佳,其状态评估准确率达到 94.7%,F1 分数达到 0.942。

未来将进一步研究不同运行状态、不同故障情况下所构建的图结构的区别及相似性,探讨变量相关性 with 运行状态的关系,挖掘图神经网络能够为深度学习模型带来的可解释性,同时,研究图稀疏化算法、图划分算法等图神经网络的加速算法,加快模型收敛速度,从而兼顾模型的性能与效率。

参考文献

[1] 杨文荣,石小晖,张雨蒙,等. 基于两轴振动和多传感

器融合的变压器绕组机械故障诊断 [J]. 电子测量技术, 2023, 46(19): 132-139.

YANG W R, SHI X H, ZHANG Y M, et al. Transformer winding mechanical fault diagnosis based on two-axis vibration and multi-sensor fusion [J]. Electronic Measurement Technology, 2023, 46 (19): 132-139.

[2] 廖才波,杨金鑫,胡雄,等. 数据与经验混合驱动下的变压器故障分层诊断方法 [J]. 高电压技术, 2023, 49(5): 1841-1850.

LIAO C B, YANG J X, HU X, et al. Hierarchical diagnosis method for transformer faults driven by mixed data and experience [J]. High Voltage Engineering, 2023, 49(5): 1841-1850.

[3] 王雨虹,王志中,付华,等. 多策略改进麻雀算法与 BiLSTM 的变压器故障诊断研究 [J]. 仪器仪表学报, 2022, 43(3): 87-97.

WANG Y H, WANG ZH ZH, FU H, et al. Research on transformer fault diagnosis based on the improved multi-strategy sparrow algorithm and BiLSTM [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 87-97.

[4] 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.

ZHANG CH L, HE Y G, DU B L, et al. Intelligent fault diagnosis method of power transformer using deep learning [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(1): 81-89.

[5] 洪翠,邱仕达,高伟. CEEMDAN 与 GCN 结合的配电变压器故障诊断 [J]. 电子测量与仪器学报, 2022, 36(12): 86-96.

HONG C, QIU SH D, GAO W. Fault diagnosis of distribution transformer based on CEEMDAN and GCN [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(12): 86-96.

[6] 邵宁宁,王英. 基于 Adam 优化的改进 PSO-RBF 牵引变压器故障诊断研究 [J]. 电气工程学报, 2023, 18(4): 209-216.

SHAO N N, WANG Y. Research on PSO-RBF traction transformer fault diagnosis based on adam optimization [J]. Journal of Electrical Engineering, 2023, 18 (4): 209-216.

[7] 谢国民,林忠宝. 多策略改进黏菌算法阶段优化 HSVM 变压器故障辨识 [J]. 电子测量与仪器学报, 2024, 38(3): 67-76.

XIE G M, LIN ZH B. ISMA algorithm stage optimization for HSVM transformer fault identification [J]. Journal of Electronic Measurement and Instrumentation, 2024,

- 38(3): 67-76.
- [8] 邹阳,俞豪奕,金涛. 融合模糊 K 近邻及证据理论的变压器油纸绝缘状态评估方法 [J]. 电力系统保护与控制, 2023, 51(14): 55-63.
- ZOU Y, YU H Y, JIN T. Evaluation method of the oil-paper insulation condition of a transformer based on fuzzy K nearest neighbor and evidence theory [J]. Power System Protection and Control, 2023, 51(14): 55-63.
- [9] 邵凯旋,何怡刚,汪磊. 基于多尺度熵分析与改进 SVM 的变压器故障识别 [J]. 电子测量与仪器学报, 2022, 36(6): 161-168.
- SHAO K X, HE Y G, WANG L. Fault identification of transformer based on multiscale entropy analysis and improved SVM [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(6): 161-168.
- [10] 范贤浩,刘捷丰,张懿议,等. 融合频域介电谱及支持向量机的变压器油浸纸绝缘老化状态评估 [J]. 电工技术学报, 2021, 36(10): 2161-2168.
- FAN X H, LIU J F, ZHANG Y Y, et al. Aging evaluation of transformer oil-immersed insulation combining frequency domain spectroscopy and support vector machine [J]. Transactions of China Electrotechnical Society, 2021, 36(10): 2161-2168.
- [11] 杨童亮,胡东,唐超,等. 基于 SMA-VMD-GRU 模型的变压器油中溶解气体含量预测 [J]. 电工技术学报, 2023, 38(1): 117-130.
- YANG T L, HU D, TANG CH, et al. Prediction of dissolved gas content in transformer oil based on SMA-VMD-GRU model [J]. Transactions of China Electrotechnical Society, 2023, 38(1): 117-130.
- [12] XING ZH K, HE Y G, CHEN J F, et al. Health evaluation of power transformer using deep learning neural network [J]. Electric Power Systems Research, 2023, 215: 109016. 1-109016. 10.
- [13] 李斌,宋威,赵凯,等. 基于 mRMR-GRU 的风电机组运行状态评估 [J]. 可再生能源, 2023, 41(7): 906-911.
- LI B, SONG W, ZHAO K, et al. Wind turbine operating condition evaluation based on mRMR-GRU [J]. Renewable Energy Resources, 2023, 41(7): 906-911.
- [14] 马宏忠,肖雨松,孙永腾,等. 基于 ICEEMDAN 和时变权重集成预测模型的变压器油中溶解气体含量预测 [J]. 高电压技术, 2024, 50(1): 210-220.
- MA H ZH, XIAO Y S, SUN Y T, et al. Prediction of dissolved gas concentration in transformer oil based on iceemdan and time-varying weight integrated prediction model [J]. High Voltage Engineering, 2024, 50(1): 210-220.
- [15] 杜厚贤,刘昊,雷龙武,等. 基于振动信号多特征值的电力变压器故障检测研究 [J]. 电工技术学报, 2023, 38(1): 83-94.
- DU H X, LIU H, LEI L W, et al. Power transformer fault detection based on multi-eigenvalues of vibration signal [J]. Transactions of China Electrotechnical Society, 2023, 38(1): 83-94.
- [16] LIU P ZH, YU W. Capsrec: A capsule graph neural network model for social recommendation [C]. 2021 IEEE 33rd International Conference on Tools with Artificial Intelligence (ICTAI). IEEE, 2021: 359-363.
- [17] ZHAO L L, XU W R, GAO SH, et al. Cross-sentence N-ary relation classification using LSTMs on graph and sequence structures [J]. Knowledge-Based Systems, 2020, 207: 106266.
- [18] LI M ZH, ZHU ZH X. Spatial-temporal fusion graph neural networks for traffic flow forecasting [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 35(5), 4189-4196.
- [19] 郑毅,王承民,刘保良,等. 基于多层级时空图神经网络的风电机组在线异常检测 [J]. 电力系统自动化, 2024, 48(5): 107-119.
- ZHENG Y, WANG CH M, LIU B L, et al. Online anomaly detection of wind turbines based on hierarchical spatio-temporal graph neural network [J]. Automation of Electric Power Systems, 2024, 48(5): 107-119.
- [20] 刘颖,李阳光,瞿树晖,等. 知识嵌入式图神经网络在风机多元状态预测中的应用 [J]. 中国科学:信息科学, 2022, 52(10): 1870-1882.
- LIU Y, LI Y G, QU SH H, et al. Application of knowledge-embedded graph neural network for multivariate state prediction of wind turbines [J]. SCIENTIA SINICA Informationis, 2022, 52(10): 1870-1882.
- [21] LUO D SH, FANG J, HE H Y, et al. Prediction for dissolved gas in power transformer oil based on TCN and GCN [J]. IEEE Transactions on Industry Applications, 2022, 58(6): 7818-7826.
- [22] DEFFERRARD M, BRESSON X, VANDERGHEYNST P. Convolutional neural networks on graphs with fast localized spectral filtering [C]. NIPS'16: Proceedings of the 30th International Conference on Neural Information Processing Systems, 2016:3844-3852.
- [23] LI T F, ZHOU ZH, LI S N, et al. The emerging graph neural networks for intelligent fault diagnostics and prognostics: A guideline and a benchmark study [J]. Mechanical Systems and Signal Processing, 2022, 168: 108653.
- [24] DIEHL F. Edge contraction pooling for graph neural networks [J]. ArXiv preprint arXiv. 1905, 10990, 2019.

[25] TAMMA W R, PRASOJO R A, SUWARNO. High voltage power transformer condition assessment considering the health index value and its decreasing rate [J]. High Voltage, 2021, 6(2): 314-327.

[26] 国家电网公司运维检修部. 电网设备状态检测技术应用典型案例:2011-2013 年 [M]. 北京:中国电力出版社, 2014.

S. G. C. O. a. M. Department, Typical Cases of Application of Grid Equipment Status Detection Technology: 2011-2013 [M]. Beijing: China Electric Power Press, 2014.

作者简介



李文悦, 2019 年于南昌大学获得学士学位, 2023 年于燕山大学获得硕士学位, 现为武汉大学博士研究生, 主要研究方向为能源装备的故障诊断及状态监测。

E-mail: wenyuel@whu.edu.cn

Li Wen Yue received her B. Sc. degree

from Nanchang University in 2019, M. Sc. degree from Yanshan University in 2023. Now she is Ph. D. candidate in Wuhan University. Her main research interests include fault diagnosis method and condition monitor of the energy equipment.



何怡刚(通信作者), 1996 年于西安交通大学获得博士学位, 现为武汉大学教授, 主要研究方向为混合信号电路故障诊断、电子设备可靠性和通信信道建模与监测等。

E-mail: yghe1221@whu.edu.cn

He Yigang (Corresponding author) received his Ph. D. degree from Xi'an Jiaotong University in 1996. Now he is a professor in Wuhan University. His main research interests include mixed signal circuit fault diagnosis, electronic equipment reliability and communication channel modeling and monitoring.