

DOI: 10.13382/j.jemi.B2205740

CEEMDAN 与 GCN 结合的配电变压器故障诊断*

洪 翠 邱仕达 高 伟

(福州大学电气工程与自动化学院 福州 350108)

摘要:针对配电变压器故障特征提取困难、故障识别难度大的问题,提出一种将振动信号、自适应噪声完备集合经验模态分解(CEEMDAN)与图卷积神经网络(GCN)三者有机结合的故障诊断方法。首先,采用CEEMDAN对来自加速度传感器的振动信号进行处理,获得一组固有模态分量(intrinsic modal function);其次求取边际谱信息作为特征向量;然后,对特征向量矩阵构造无向加权完全图,并使用改进灰狼优化算法对高斯核带宽进行寻优;最后,搭建一个具备多通道和多连通的改进GCN模型进行特征二次挖掘与故障分类。与此同时,还在模型中加入一种名叫“峰值因子”指标实现对未知类型故障的辨识。在实例分析中,分别对油浸式和干式变压器进行故障模拟,提取不同状态的样本进行测试。实验结果表明,所提方法对油浸式和干式变压器的故障识别准确率分别达到97.73%和95.6%,优于其他两种对比方法。在面对未知类型故障以及运行工况发生变化时,也具备较高识别能力。

关键词: 配电变压器;故障诊断;振动信号;CEEMDAN;GCN

中图分类号: TM41;TN06 **文献标识码:** A **国家标准学科分类代码:** 4704051

Fault diagnosis of distribution transformer based on CEEMDAN and GCN

Hong Cui Qiu Shida Gao Wei

(College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China)

Abstract: Aiming at the difficulty of fault feature extraction and fault identification of distribution transformers, a fault diagnosis method combining vibration signals, complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) and graph convolution neural networks (GCN) was proposed. Firstly, the vibration signal from the acceleration sensor is processed by CEEMDAN to obtain a set of intrinsic modal functions. Secondly, its marginal spectrum information is taken as the feature vector. Then, an undirected weighted complete graph is constructed for the eigenvector matrix, and an improved gray wolf optimization algorithm is used to optimize the Gaussian kernel bandwidth. Finally, an improved GCN model with multi-channel and multi-connectivity is built for feature secondary mining and fault classification. At the same time, an index called peak factor is added to the model to realize the identification of unknown faults. In the case analysis, the fault simulation of oil-immersed transformer and dry transformer is carried out respectively, and samples of different states are extracted for testing. The experimental results show that the accuracy of the proposed method for oil-immersed transformer and dry transformer fault identification is 97.73% and 95.6%, respectively, which is better than the other two comparison methods. In the face of unknown types of faults and operating conditions change, it also has a high ability to identify.

Keywords: distribution transformer; fault diagnosis; vibration signal; complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN); graph convolution network (GCN)

0 引言

配电变压器是配电网中的核心设备,突发性的故障会造成重大的安全事故与经济损失。据统计,每年因变压器故障导致的事故不可胜数^[1]。因此,为确保配电网系统正常运行,对配电变压器运行状态进行监测是非常有必要。

基于振动信号分析的方法是当前变压器故障检测技术研究热点之一^[2]。此类方法将位移、速度或加速度传感器安装于变压器的支撑件、绕组侧面或油箱表面^[3],采集振动信号来分析变压器运行状态,甚至识别故障类型,具有安装方便、灵活、无电气连接等优点。

为了提取变压器的代表性特征,需要对振动信号进行分解。文献[4]使用交叉小波变换提取变压器振动信号的主成分,该方法虽然具有良好的局部时频特性,但分解的效果和性能依赖于小波基函数的选取。文献[5]利用变分模态分解(variational mode decomposition, VMD)对信号进行处理,获取最优模态。VMD虽然能降低时间序列复杂度,但需预先确定分解数量。经验模态分解(empirical mode decomposition, EMD)是一种自适应的分解算法,克服了小波变换基函数选取困难及VMD需预先确定分解数的问题,但其最大问题在于容易出现模态混叠现象。因此,文献[6]使用集合经验模态分解(ensemble empirical mode decomposition, EEMD)提取绕组故障的振动信号特征。EEMD虽然在一定程度上解决了模态混叠现象,但依然存在计算量大、复杂度高等弊端。为此,文献[7]使用自适应噪声的完备集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN),获取振动信号各模态的特征。CEEMDAN是对EEMD进一步改进,可有效降低计算的复杂度,因此,本研究使用CEEMDAN对配电变压器振动信号进行处理。

从复杂的振动信号中获取具有代表性特征后,需要对其进行分类。文献[8]对变压器各相绕组的顶部和正面的振动信号变化设定阈值,以识别绕组松动缺陷,但所提阈值无法辨识绕组变形与铁芯故障。随着人工智能技术的发展,越来越多学者使用人工智能方法来识别变压器运行状态。文献[9]使用支持向量机(support vector machine, SVM)识别变压器的运行状态。虽然SVM的求解速度快,但诊断精度较低,并且文献[9]涉及故障类型较少,特征缺乏一定的代表性,经测试发现会因为所提特征不明显使得诊断精度下降。文献[10]使用随机森林(random forest, RF)分类器对变压器进行监测,RF可训练大样本数据,但模型比较容易陷入过拟合。文献[11]用堆栈自编码器自动学习特征并结合朴素贝叶斯分类器

辨识变压器的运行状态。该方法虽能有效地提取振动信号的特征,但朴素贝叶斯模型在属性个数较多或者属性间相关性较大时,分类效果不佳。近年来,神经网络模型良好的分类性能获得众多学者的认可,其中图卷积神经网络(graph convolution networks, GCN)^[12]在对文本分类、动作识别领域取得成功应用,证明了其优秀的分类性能。在对设备故障诊断领域的应用中,国内相关学者已开展相关研究工作。如文献[13]将样本数据作为图中节点构造图数据,建立GCN模型实现滚动轴承故障分类,获得了较高的诊断精度。GCN在学习各个节点特征时充分考虑节点间的联系与影响,从而提高了模型的诊断精度。因此,本研究引入GCN用于辨识配电变压器的运行状态。

基于以上分析,本文提出一种结合CEEMDAN与GCN的配电变压器故障诊断方案。首先,采用CEEMDAN与希尔伯特变换(Hilbert transform)提取配电变压器振动信号的边际谱特征来表征不同状态的差异。其次,在构造无向加权完全图求取邻接矩阵中使用改进灰狼优化算法(improved gray wolf optimization, IGWO)实现对高斯函数核带宽寻优,解决参数难以选取问题。最后,使用改进的GCN实现对不同频带的边际谱特征二次挖掘与故障分类。此外,还提出计算模型输出层的峰值因子解决传统方法对未知类型故障无法辨识的问题。

1 算法介绍

1.1 基于CEEMDAN的边际谱信息提取

Torresm等^[14]提出CEEMDAN算法,可有效解决EMD及其衍生算法模态混叠、计算量大的问题,但CEEMDAN在分解时会产生伪模态。Colominas等^[15]提出通过添加受控的自适应噪声消除CEEMDAN产生的伪模态,确保分解所得信号的物理意义。实现过程如下:

1) 在第1阶段,首先计算 $x_i = x + \beta_0 E_1(n_1)$ 的局部均值,获得第1余量 r_1 与第1个模态分量:

$$r_1 = \frac{1}{N} \sum_{i=1}^N M(x_i) \quad (1)$$

$$IMF_1 = x - r_1 \quad (2)$$

式中: $i=1, 2, \dots, N$, N 为噪声添加次数。并且 E_j 表示通过EMD获取的 j 阶IMF分量; n_i 表示均值为0、方差为1的高斯白噪声; M 表示局部均值算子; x 为原信号; ε_0 为用于控制辅助噪声与原始信号信噪比的系数,且在计算第 k 个模态分量时产生新的自适应系数 β_{k-1} ,控制向上一阶段余量添加噪声的大小,当 $k=1$ 时, $\beta_0 = \varepsilon_0 \text{std}(x) / \text{std}(E_1(n_i))$,当 $k \geq 2$ 时, $\beta_{k-1} = \varepsilon_0 \text{std}(r_{k-1})$; std 表示标准差。

2) 在第 $k=2, 3, \dots, m$ 阶段中,首先对上一阶段的余量 r_{k-1} 添加受控的自适应噪声信号 $r_{k-1} + \beta_{k-1} E_k(n_i)$,并

计算其局部均值获得第 k 个余量与第 k 个模态分量:

$$r_k = \frac{1}{N} \sum_{i=1}^N M(r_{k-1} + \beta_{k-1} E_k(n_i)) \quad (3)$$

$$IMF_k = r_{k-1} - r_k \quad (4)$$

3) 当余量 r 满足终止条件时,原信号 x 被分解为:

$$x = \sum_{k=1}^m IMF_k + r \quad (5)$$

计算 Hilbert 边际谱时,首先对分解得到的 m 阶 IMF 分量进行 Hilbert 变换。对第 k 个 IMF 分量的 Hilbert 变换为:

$$H[IMF_k(t)] = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{IMF_k(\tau)}{t - \tau} d\tau \quad (6)$$

第 k 个 IMF 分量的瞬时幅值表达式为:

$$a_k(t) = \sqrt{IMF_k(t)^2 + H[IMF_k(t)]^2} \quad (7)$$

第 k 个 IMF 分量的瞬时相位表达式为:

$$\phi_k(t) = \arctan\left(\frac{H[IMF_k(t)]}{IMF_k(t)}\right) \quad (8)$$

第 k 个 IMF 分量的瞬时频率表达式为:

$$\omega_k(t) = \frac{d}{dt}[\phi_k(t)] \quad (9)$$

$$H(\omega, t) = \text{Re} \sum_{k=1}^m a_k(t) \exp(j \int \omega_k(t) dt) \quad (10)$$

式中: $H(\omega, t)$ 即为原信号 x 的 Hilbert 谱,随后对其积分获得 Hilbert 边际谱 $B(\omega)$:

$$B(\omega) = \int_{-\infty}^{\infty} H(\omega, t) dt \quad (11)$$

Hilbert 边际谱能表征信号在每个瞬时频率上的幅值分布情况。以油浸式变压器绕组松动状态与铁芯两点故障状态为例,先以 CEEMDAN 分解振动信号,再计算 Hilbert 边际谱,结果如图 1 所示。

从图 1 中对比可见,不同频带的边际谱信息可以有效表征出配电变压器不同运行状态的差异。


1.2 图卷积神经网络及其改进

GCN 是 Kipf 等^[12]于 2017 年提出的一种半监督分类算法,根据图模型中每个节点连接关系对顶点的原始特征进行逐层学习,自适应提取深层特征与节点分类。本文将每个变压器故障状态样本作为图模型中的节点,每个节点包含不同频带的边际谱信息,构造图模型求取邻接矩阵作为 GCN 模型的输入。


1) 图模型

图模型可按边的连接关系分为无向图与有向图;按照边的权重关系可分为加权图与无权图。其中,无向图又可分为 K -近邻图、 ψ -近邻图和完全图,如图 2 所示。

ψ -近邻图假设存在一个阈值 ψ ,任意顶点与其他点的距离在该阈值范围内都存在边连接; K -近邻图是通过近邻参数 K 构图,任意顶点与其距离最近的 K 个点存在



(a) Marginal spectrum of winding loose faults



(b) Marginal spectrum of two-point earth fault in iron core

图 1 不同状态的边际谱

Fig. 1 Marginal spectra of different states




图 2 无向图的 3 种构图方式

Fig. 2 Three kinds of composition of undirected graph

边连接;完全图则是指所有顶点之间均存在边连接。无向加权完全图,以每个样本为顶点,任意两个顶点的边连接权重由高斯函数计算。

图模型可表示为 $G = (V, E, A)$ 。模型中, V 和 E 分别表示顶点和边的集合, A 表示图模型的邻接矩阵。根据无向加权完全图的拓扑结构可求取邻接矩阵 A 作为 GCN 模型的输入:

$$A_{pq} = A_{qp} = \exp\left(\frac{-\|X_p - X_q\|^2}{\eta^2}\right) \quad (12)$$

式中: $A_{pq} = A_{qp}$ 表示两个顶点间的连接权重, η 表示高斯

核带宽, $\mathbf{X}_p, \mathbf{X}_q$ 表示特征向量矩阵 \mathbf{X} 中第 p 个与第 q 个样本的特征向量。

2) 图卷积神经网络的改进

为了从不同频率的边际谱中挖掘反映故障特征的有效信息, 本文构建了一个多通道和多连通的 GCN 模型, 如图 3 所示。

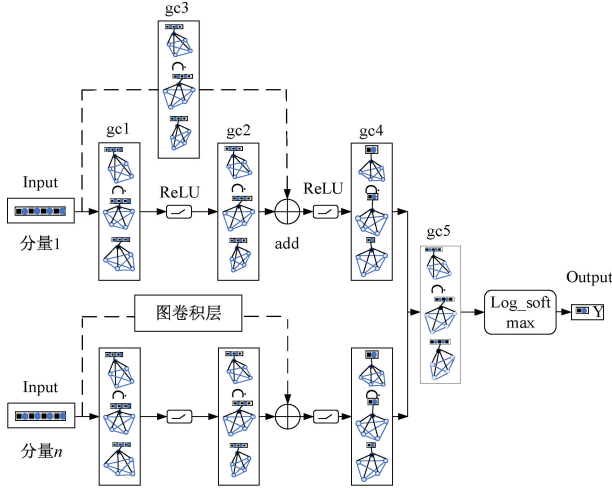


图 3 改进的 GCN 结构

Fig. 3 Improved GCN structure

该模型的每个并行通道包含多个独立的图卷积层 gc1, gc2 和 gc4 用于实现对不同频带边缘谱信息二次挖掘。为了从不同尺度提取边缘谱信息, 在前向传播网络中添加一层图卷积层 gc3, 实现多连通从而增加了 gc4 层节点特征的多样性。对各通道特征融合后连接一个图卷积层 gc5, 输出层连接一个 lg_softmax 分类器。最后采用交叉熵损失函数^[12]计算损失值, 并使用 Adam 优化器更新模型参数。GCN 前向传播过程为:

输入层:

$$\mathbf{H}_{(1)} = \sigma[\mathbf{D}^{-1/2}(\mathbf{A} + \mathbf{I})\mathbf{D}^{-1/2}\mathbf{X}\mathbf{W}_{(1)}] \quad (13)$$

隐藏层:

$$\mathbf{H}_{(2)} = \sigma[\mathbf{D}^{-1/2}(\mathbf{A} + \mathbf{I})\mathbf{D}^{-1/2}(\mathbf{H}_{(1)}\mathbf{W}_{(2)} + \mathbf{X}\mathbf{W}_{(3)})] \quad (14)$$

$$\mathbf{H}_{(4)} = \sigma[\mathbf{D}^{-1/2}(\mathbf{A} + \mathbf{I})\mathbf{D}^{-1/2}\mathbf{H}_{(2)}\mathbf{W}_{(4)}] \quad (15)$$

各通道特征融合层:

$$\mathbf{H}_{(5)} = [\mathbf{H}_{1(4)}, \mathbf{H}_{2(4)}, \dots, \mathbf{H}_{h(4)}] \quad (16)$$

输出层:

$$\mathbf{y} = [\mathbf{D}^{-1/2}(\mathbf{A} + \mathbf{I})\mathbf{D}^{-1/2}\mathbf{H}_{(5)}\mathbf{W}_{(5)}] \quad (17)$$

lg_softmax 分类:

$$Y_i = \lg\left(\frac{e^{y_i}}{\sum_{i=1}^n e^{y_i}}\right), (i = 1, 2, 3, \dots, n) \quad (18)$$

式中: $\mathbf{A} + \mathbf{I}$ 为加自环的邻接矩阵; \mathbf{I} 为单位矩阵; \mathbf{D} 是 $\mathbf{A} + \mathbf{I}$ 所对应度矩阵; $\mathbf{W}_{(l)}$ 表示第 l 层的权重; $\mathbf{H}_{(5)}$ 是各通道特

征融合的特征; h 表示通道数; $\sigma(\cdot)$ 表示激活函数 $\text{ReLU}(\cdot) = \max(0, \cdot)$; $\mathbf{y} = [y_1, y_2, \dots, y_n]$ 为输出层特征, 维度等于类别数 n ; $\mathbf{Y} = [Y_1, Y_2, \dots, Y_n]$ 为分类器输出概率值。

1.3 改进灰狼优化算法

由式(12)可见, 高斯加权函数核带宽 η 的值会影响边连接的权重, 为了使相同类型样本的边连接权重最大化, 而不同类型样本的边连接权重最小化, 故引入优化算法对其进行寻优。

1) 基本灰狼优化

Mirjalili 等^[16]于 2014 年提出了灰狼优化算法 (gray wolf optimization, GWO), 根据灰狼社会等级制度, 将狼群中适应度最好的前 3 匹狼分别定义为 α, β 和 δ , 其余定义为 ω , 由每代狼群中最优的 3 个解指导完成目标搜索及位置更新。狼群围捕猎物的数学模型为:

$$d = |\mathbf{C}\vec{\mathbf{Q}}_p(T) - \vec{\mathbf{Q}}(T)| \quad (19)$$

$$\gamma\vec{\mathbf{Q}}(T+1) = \vec{\mathbf{Q}}_p(T) - Fd \quad (20)$$

$$F = 2\gamma r_1 - \gamma \quad (21)$$

$$C = 2r_2 \quad (22)$$

式中: d 表示个体与目标之间的距离; $\vec{\mathbf{Q}}(T+1)$ 表示对灰狼位置更新; $\vec{\mathbf{Q}}_p$ 表示目标向量位置; T 是当前迭代次数; $\vec{\mathbf{Q}}$ 表示灰狼位置向量; F 和 C 为向量系数; r_1, r_2 为 $[0, 1]$ 随机数; γ 为收敛因子其值随着迭代次数增加由 2 线性减小到 0。

对灰狼位置的迭代寻优时, 基于 α, β, δ 狼对狼群指导位置向量的模值, 引入学习权重更新灰狼位置。

$$\begin{cases} \vec{\mathbf{Q}}_\alpha = \vec{\mathbf{Q}}_\alpha - F|C \cdot \vec{\mathbf{Q}}_\alpha - \vec{\mathbf{Q}}| \\ \vec{\mathbf{Q}}_\beta = \vec{\mathbf{Q}}_\beta - F|C \cdot \vec{\mathbf{Q}}_\beta - \vec{\mathbf{Q}}| \\ \vec{\mathbf{Q}}_\delta = \vec{\mathbf{Q}}_\delta - F|C \cdot \vec{\mathbf{Q}}_\delta - \vec{\mathbf{Q}}| \end{cases} \quad (23)$$

$$\begin{cases} \theta_\alpha = \frac{|\vec{\mathbf{Q}}_\alpha|}{|\vec{\mathbf{Q}}_\alpha| + |\vec{\mathbf{Q}}_\beta| + |\vec{\mathbf{Q}}_\delta|} \\ \theta_\beta = \frac{|\vec{\mathbf{Q}}_\beta|}{|\vec{\mathbf{Q}}_\alpha| + |\vec{\mathbf{Q}}_\beta| + |\vec{\mathbf{Q}}_\delta|} \\ \theta_\delta = \frac{|\vec{\mathbf{Q}}_\delta|}{|\vec{\mathbf{Q}}_\alpha| + |\vec{\mathbf{Q}}_\beta| + |\vec{\mathbf{Q}}_\delta|} \end{cases} \quad (24)$$

$$\vec{\mathbf{Q}}(T+1) = \frac{\theta_\alpha \vec{\mathbf{Q}}_\alpha + \theta_\beta \vec{\mathbf{Q}}_\beta + \theta_\delta \vec{\mathbf{Q}}_\delta}{3} \quad (25)$$

式(23)表征狼群朝向 α, β, δ 移动的距离与步长, 式(24)定义狼群对 3 头向导狼的学习权重, 式(25)确定狼群的最终位置。

2) 收敛因子衰减策略

GWO 的收敛因子随着迭代次数增加而递减,显然会极大的影响算法的搜索能力。因此,文献[17-18]提出一种非线性收敛因子来改善算法在全局搜索和局部搜索间的平衡性。该因子在算法执行初期减缓 γ 衰减速度提高全局搜索能力;在算法后期加快 γ 衰减速度的同时提高了 γ 值,导致算法后期的扰动增大。基于此,本文提出一种带正弦函数的非线性收敛因子:

$$\gamma = 2 - 2 \frac{T}{T_{\max}} \sin\left(\frac{\pi}{2} \frac{T}{T_{\max}}\right) \quad (26)$$

其中, T_{\max} 为最大迭代次。

图 4 所示为不同收敛因子的效果比较。由图 4 可知,所提收敛因子保留了算法执行初期降低 γ 衰减速度的特点;算法后期在提高 γ 衰减速度且获得较小的值以避免最优解动荡,加快算法收敛。




图 4 不同收敛因子对比

Fig. 4 Comparison of different convergence factors

1.4 未知类型故障的辨识

传统基于监督式学习的故障诊断模型,仅能对已知类型的故障即模型训练过的故障类别进行辨识,而对未知类型故障识别效果不佳,通常会将其误判为最相似的一类。对模型所提特征向量 \mathbf{y} 进一步分析可知,与已知类型故障相比,未知类型故障的特征向量 \mathbf{y} 的峰值和有效值方面存在差异。因此,本文考虑构造峰值因子 f ,用以实现已知类型故障与未知类型故障在特征层面分层:

$$f = \frac{y_{\text{peak}}}{\sqrt{\frac{1}{n} \sum_{i=1}^n y_i^2}} \quad (27)$$

式中: \mathbf{y} 表示输出层的特征向量, n 为类别数, y_{peak} 为峰值。

图 5 所示为 1 200 个已知故障类型和 300 个未知故障类型在峰值因子上的差异。

其中,已知故障类型的样本,在经过训练集训练后,峰值因子相对集中,而未知故障类型的计算结果会分散到两端。即只要选择合适的阈值,就可以对未知类型的故障进行准确辨识。它们的边界,可以根据统计学原理




图 5 峰值因子分布

Fig. 5 The distribution of the crest factor

进行计算。

在添加了未知类型故障模块后,对于每个测试样本,其识别流程调整为:

1) 获得 GCN 输出层特征向量 \mathbf{y} ;

2) 计算 \mathbf{y} 峰值因子 f ;

3) 判断 f 是否在训练集的峰值因子的上下限范围内,若不在,则表示为未知类型故障;反之则为已知类型故障,对 \mathbf{y} 计算 lg_softmax ,确定故障类型。

2 配电变压器故障诊断算法

本文提出将 CEEMDAN 与 GCN 相结合的配电变压器故障诊断方案,工作流程如图 6 所示。实现步骤如下:

1) 通过采集装置获得配电变压器的振动信号;

2) 对所采数据进行 CEEMDAN,从而获得一组模态分量;并根据波形及相关性求取高频、基频与低频 3 个分量的边际谱,构成特征向量矩阵;

3) 构造无向加权完全图,并使用 IGWO 对高斯函数的核带宽寻优,求取邻接矩阵;

4) 搭建改进的 GCN 模型,训练并保存最优模型;

5) 统计计算峰值因子的边界范围;

6) 用测试样本验证模型诊断精度。

3 实验系统及故障模拟

3.1 振动信号采集系统

配电变压器振动信号采集系统如图 7 所示,由加速度传感器、振动信号采集装置及上位机软件组成。

该系统采用型号为 LC0156A 的压电式加速度传感器,采集卡选择 NI USB-6218;上位机软件由 MATLAB 和 LabVIEW 混合编程开发。

3.2 故障模拟

故障模拟对象,分别选取了 S11-M-315/10 油浸式变压器和物理结构与 10 kV 干式变相同、容量为 30 kVA 的 380 V/380 V 干式变压器。振动信号采集装置的采样

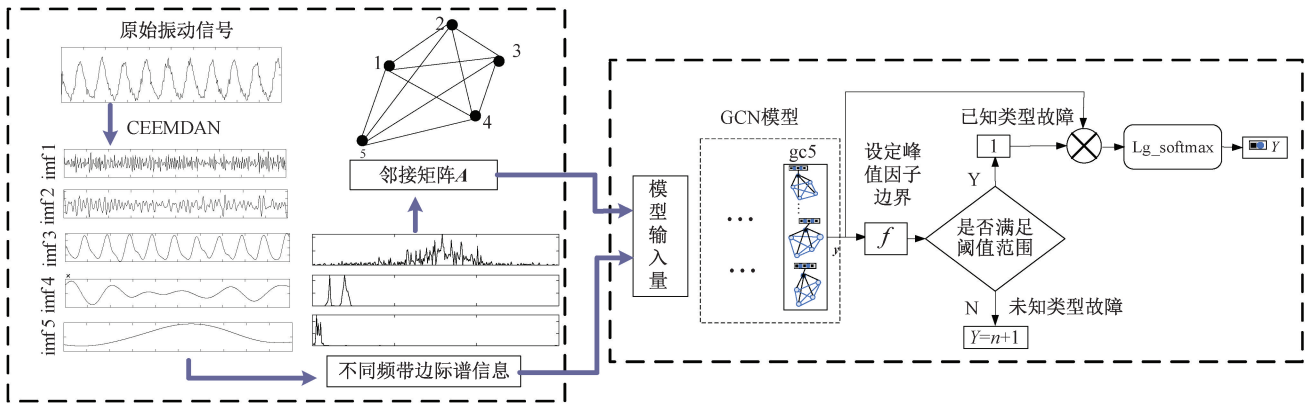


图 6 所提算法的工作流程

Fig. 6 Workflow of proposed algorithm



图 7 振动信号采集装置

Fig. 7 Vibration signal acquisition device




图 8 油浸式变压器的故障模拟

Fig. 8 Fault simulation in oil immersed transformer

率为 3 kHz, 采样时间为 0.1 s, 即每个样本采集 300 个数据点。据文献[19-20]对变压器振动测点的研究可知, 由于 B 相的振动受 A、C 两相影响, 振动强度较大。考虑安全性等因素将加速度传感器安装于 0.4 kV 出线侧对应于 B 相绕组的油箱表面中部。

图 8 所示为对油变故障模拟情况。故障模拟时, 调节绕组轴向压紧螺母, 减小绕组的压紧力来模拟绕组松动状态; 在 AB 两相的低压绕组与铁芯之间垫木块模拟绕组变形故障; 通过调节横向紧固螺栓的螺母来模拟铁芯松动故障; 给铁芯安装接地片, 使铁芯具有两个接地点, 模拟铁芯两点接地故障。故障模拟前, 需要先将实验油抽出, 并吊出机构, 进行故障模拟操作后, 再装入变压器油。

故障模拟完成后对变压器进行实验, 由于油浸式变压器容量较大, 无法在带载的情况下进行故障实验。本文通过对油浸式变压器进行常规的空载实验收集绕组变形与绕组松动状态下油箱表面的振动信号。将试验变压器低压侧三相短路, 高压侧接三相调压器, 使得低压侧电流分别为额定电流的 80%、90%、100%、110%来模拟不同负载的运行状态。对变压器进行常规的空载实验收集铁芯两点接地与铁芯松动状态下油箱表面的振动信号, 在

试验变压器低压侧连接三相调压器, 高压侧开路, 调节低压侧电压 360、380、400、420、440 V。在短路实验与空载实验下采集了油变的正常情况、绕组变形、绕组松动、铁芯两点接地故障及铁芯松动 5 种运行状态下的实验数据, 分别记为状态 1~状态 5。

此外, 作者实验室有一台 380 V/380 V 配电网物理仿真系统使用的干式变压器, 其物理结构与 10 kV 干式变压器相同的变压器, 容量为 30 kVA。因此本文选定在该平台的干式变压器上进行故障模拟, 由于受制于实验条件, 在不对变压器进行破坏性实验下模拟了螺丝松动和铁芯多点接地两种故障如图 9 所示, 并采集了正常运行、螺丝松动和铁芯多点接地 3 种运行状态的实验数据共 1 800 组。



图 9 干式变压器的故障模拟

Fig. 9 Fault simulation in dry transformer

4 信号分析与参数设置

4.1 原始信号分析

以油变为例,各状态原始信号如图 10 所示。由图可见,虽然不同状态的幅值与波形存在差异,但时域波形复杂干扰较多。

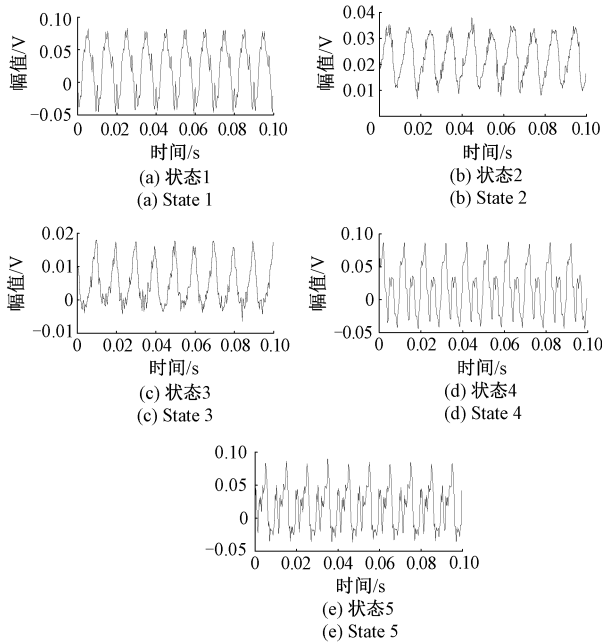


图 10 各个状态的原始波形
Fig. 10 Original waveform of each state

图 11 所示为图 10 对应各状态的频谱。可见,信号中含有较大的直流分量;绕组故障时频率主要集中在 100、200 及 300 Hz;绕组变形与绕组松动时各频率幅值存在差异;发生铁芯故障时,200 Hz 的振动强度增大,如两点接地故障 200 Hz 分量大于 100 Hz。




图 11 各状态的频谱
Fig. 11 Spectrum of each state

4.2 CEEMDAN 的参数设置

CEEMDAN 主要包括 ε_0 和 N 两个参数。辅助噪声与

原始信号信噪比 ε_0 是用来抑制模态混叠现象的发生。 ε_0 取大或取小,均会导致部分分量发生模态混叠,文献 [14-15] 给出的推荐值为 0.2,适用于大部分的信号。辅助噪声添加次数 N 越大,即对分解结果的平均处理次数越多,有利于消除所添加的噪声对分解造成的影响,但计算量也越大。通过分析 N 值的变化,主模态分量与原始信号的相关性如表 1 所示,可以发现随着 N 为变大,相关性逐渐提升,但 N 超过 20 后,相关性基本趋于稳定。综合相关性和计算量, N 取 20。

表 1 主模态分量与原始信号相关性与 N 的变化关系

Table 1 Correlation between the main modal component and the original signal with the change of N

N	10	20	30	40	50
状态 1	0.930	0.959	0.958	0.958	0.959
状态 2	0.930	0.973	0.973	0.973	0.974
状态 3	0.904	0.952	0.951	0.949	0.949
状态 4	0.782	0.835	0.831	0.831	0.836
状态 5	0.720	0.782	0.776	0.780	0.783

4.3 GCN 模型的参数

改进 GCN 模型的参数设置如表 2 所示,各层的编号与 1.2 节图 3 相同。

表 2 参数设置

Table 2 Parameter setting

图卷积层	输入维度—输出维度	模型参数	
gc1	300—32	dropout	0.5
gc2	32—16	最大迭代次数	100
gc3	300—16	weight	5×10^{-4}
gc4	16—5	初始学习率	0.05
gc5	15—5		

本文以训练集和验证集共 1 500 组样本为例,GCN 模型的输入为 $1\,500 \times 300$ 的矩阵,将 1 500 个样本分别作为无向加权完全图的顶点,根据 1.2 节中式 (12) 获得 $1\,500 \times 1\,500$ 的邻接矩阵 A ,邻接矩阵 A 会随着输入模型的样本数改变而变化。

4.4 参数寻优

为了获得最优的高斯加权函数核带宽 η ,使用 IGWO 进行寻优。以训练集 1 200 个样本为例,选取邻接矩阵 A 中不同标签顶点间的连接权重总和与相同标签顶点间的连接权重总和之比为目标函数,目标函数值越小所获得的邻接矩阵越优,狼群数量设为 20,最大迭代次数设为 10 次,搜索空间设为 (0.1, 5)。同时与 GA、原生 GWO、PSO 算法及使用文献 [17] 与文献 [18] 提出的非线性收敛因子改进的 GWO 对比。本文所用计算机的处理器为 Intel® Core (TM) i5-10200 H,显卡为 GTX-1650,寻优结果如表 3 所示。

表 3 不同优化算法结果

Table 3 Results of different optimization algorithms

模型	评价指标		
	训练时间 (迭代 10 次)/min	目标函数最优值	最优核带宽
PSO	27.96	1.35×10^{-5}	0.152
GA	26.56	0.616	0.960
GWO[16]	29.22	3.93×10^{-5}	0.145
GWO[17]	28.86	3.83×10^{-7}	0.128
GWO[18]	28.92	4.597×10^{-7}	0.133
IGWO	28.6	3.43×10^{-7}	0.125

在最大迭代次数相同条件下, PSO 所需的时间较短, 但其寻优结果容易陷入局部最优; GA 算法所需时间最短, 但经过 10 次迭代后所求目标函数值最大, 寻优效果不佳。相比于 PSO 与 GA, 虽然原生 GWO 所需时间较长, 但其寻优效果更佳, 局部寻优与全局搜索的平衡性好; GWO 所需时间为 29.22 min, 而使用文献[17-18]所提收敛因子与本文所提对 GWO 改进所需的时间均优于原生 GWO; 经比较可知, 所提改进方法获得的目标函数值最小, 经 10 次迭代所需时间为 28.6 min。因此, 最终寻优结果为 $\eta = 0.125$ 。

5 对比和分析

5.1 不同运行工况下故障诊断

为验证所提方案在变压器不同工况下的诊断效果, 以油浸式变压器为例。将额定工况样本划分为训练集 1 200 组、验证集 300 组用于模型训练。测试集包含 5 种状态, 每种状态各有多种不同运行工况, 共计 3 600 组样本。对诊断结果绘制混淆矩阵, 如图 12 所示。




图 12 混淆矩阵表示的测试结果

Fig. 12 Confusion matrix of test set classification results

其中 6 表示未知类型故障, 所提方案对变压器正常

情况, 绕组变形, 绕组松动, 铁芯两点接地及铁芯松动 5 种状态均能准确识别, 准确率达 97.73%。

表 4 与 5 分别表示使用额定工况下训练的模型对工况波动样本的测试结果, I_N 表示低压侧额定电流。

表 4 不同负载电流下的诊断结果

Table 4 Diagnostic results of different load currents

状态	工况		
	$110\%I_N$	$90\%I_N$	$80\%I_N$
绕组变形	98	99.33	98.29
绕组松动	99.75	99.2	100

表 5 不同空载电压下诊断结果

Table 5 Diagnosis results under different no-load voltages

状态	工况			
	440 V	420 V	380 V	360 V
铁芯松动	94.75	94.33	95	94.5
铁芯两点接地	100	100	99.67	100
正常	98.5	96.5	99.5	98.33

可见, 绕组松动、正常与铁芯两点接地状态受变压器运行工况波动影响较小。在空载电压波动下, 对铁芯松动故障诊断准确率较低为 94.33%~95%; 铁芯两点接地故障诊断准确率较高。通过观察发现, 铁芯松动故障发生错判的样本, 被误判为铁芯两点接地故障与未知类型故障。在负载电流变化下, 对绕组变形故障的诊断准确率波动较大, 其中所有辨识错误样本均被误判为绕组松动状态与未知类型故障。由此表明, 所提方案虽然对不同工况的诊断具有一定精度, 但对铁芯松动故障的辨识无法完全克服工况波动的影响。

5.2 改进的 GCN 性能评估

1) 不同构图方式比较

不同的构图方式, 获得的邻接矩阵也不同, 特征提取效果也会存在差异。对无向加权完全图与 $K=3$ 和 $\psi=0.4$ 的近邻图进行比较, 在相同的网络结构下, 对 gc5 层的特征做 t-SNE^[21] 二维可视化如图 13 所示。图 13 (a) 中状态 2 与状态 3 的特征分布散乱且独立成块, 由此说明使用 $\psi=0.4$ 近邻图的拓扑结构获得的邻接矩阵, 对特征聚合效果较差。图 13 (b) 所示使用 $K=3$ 近邻图求邻接矩阵, 获得不同状态的特征均有部分独立成块, 且不同状态的特征存在混叠部分, 对不同类型样本的分离效果不如其他两种构图方式。显然, 所提使用无向加权完全图求取邻接矩阵, 获得的特征对相同类型样本的聚合效果与对不同类型样本的分离效果均优于对比方法。

2) 分类性能比较

为了进一步评估 GCN 改进后的性能, 以油浸式变压

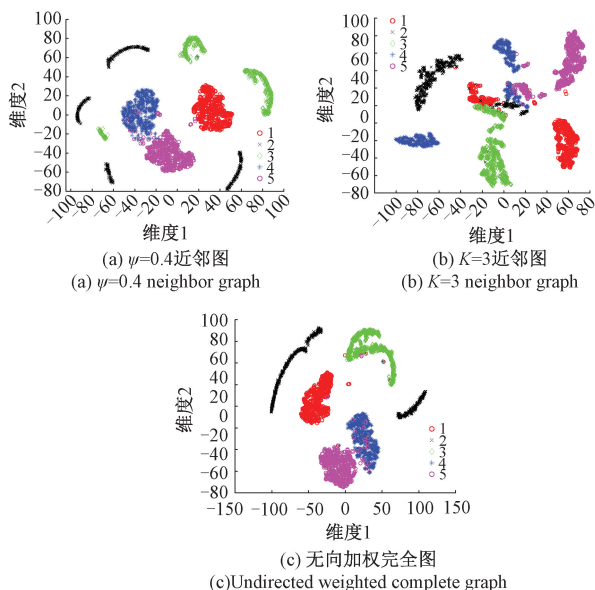


图 13 不同构图方式比较

Fig. 13 Comparison of different composition methods

器变数据为例构造了如下几个对比模型,分别使用传统 GCN,SVM,RF 分类器对边际谱特征分类以及使用 GCN 对原始信号进行特征提取和分类;各模型的诊断结果如表 6 所示。

表 6 各类方法的性能对比

Table 6 Performance comparison of each method

模型	准确率/%
原始信号+GCN	86.73
边际谱特征+SVM	92.78
边际谱特征+RF	92.81
边际谱特征+GCN	93.83
所提方案	97.73

由表 6 可见,使用 SVM 与 RF 的辨识精度均低于传统 GCN 模型的分类精度,而传统 GCN 模型分类准确率低于所提方案。由此说明改进的 GCN 能有效从不同尺度挖掘深层特征,提高模型分类准确率。直接使用 GCN 来提取原始信号特征,准确率比所提方案低了 11% 左右。说明相对于端到端的机器学习模型,所提的特征提取方法使故障信息更加清晰,提高模型的学习质量。

5.3 未知类型故障检测

验证本文所提方案对未知类型故障的检测性能。将 S11-M-315/10 油浸式变压器低压侧 BC 两相短路,A 相开路,高压侧接三相调压器,收集了 300 组不同工况的 BC 短路故障样本作为未知类型故障并使用 5.1 节训练的模型(模型 1)进行直接辨识。其次,将数据集中任意一种状态的样本排除,重新训练诊断模型,然后对 300 组 BC 短路故障样本进行测试。

表 7 列出 5 个模型的测试结果和峰值因子 f 的上下限。可以发现:1)各模型对 BC 短路故障的辨识结果均能达到 90% 及以上;2)诊断模型的状态类型和数量发生变化, f 的边界值会出现些许变化,但分布的区间相对稳定,所提的方案都可以对未知类型故障进行识别。值得一提的是,尽管所提方案能改善传统故障诊断方法无法辨识未知类型故障的问题,但它是以降低模型对已知类型故障的诊断精度为代价来实现的。

表 7 未知类型故障诊断结果

Table 7 Unknown type fault diagnosis result

名称	训练集排除的故障类型	f 的上下限	BC 短路辨识结果
模型 1	BC 短路	1.209~1.821	92.76%
模型 2	状态 2、BC 短路	1.357~1.791	92.21%
模型 3	状态 3、BC 短路	1.364~1.722	94.5%
模型 4	状态 4、BC 短路	1.308~1.627	90%
模型 5	状态 5、BC 短路	1.376~1.725	93.12%

5.4 干式变压器故障状态识别

为了验证所提方案对不同类型变压器的适应性,将其应用于干变故障诊断上。由于两种变压器结构存在差异及信号传递路径不同,信号波形的成分也存在差异。因此,使用 3.2 节收集的 1 800 组干变数据集重新训练故障诊断模型,诊断结果如图 14 所示。




图 14 干式变压器的混淆矩阵

Fig. 14 Confusion matrix of dry-type transformer

图中 1~3 分别代表正常状态,螺丝松动与铁芯多点接地故障,4 表示未知类型故障,它们的分类准确率为 95.6%。由此说明,所提方案在干变上也适用,由于干变故障特征的信号谱差异较小,所以其识别准确率比油变低。

5.5 算法对比

为了验证所提方案的分类性能,将其与文献[9]、[11]方法对比。文献[9]提取变压器振动信号 6 个时频域特征,并利用支持向量机做分类。文献[11]利用堆栈自编码器与贝叶斯分类器相结合实现对变压器故障诊

断。利用油浸式变压器与干式变压器数据集,分别将所提方案与文献[9]和文献[11]进行对比,如表 8 所示。

表 8 不同方法的测试结果对比

Table 8 Comparison of test results with different methods

方法	变压器类型	准确率/%
文献[9]	油浸式变压器	92.8
	干式变压器	88.56
文献[11]	油浸式变压器	96.3
	干式变压器	80.33
所提方案	油浸式变压器	97.73
	干式变压器	95.6

文献[9]与[11]的方法应用于油浸式变压器准确率为 92.8%和 96.3%,然而它们应用于干式变压器的准确率仅为 88.56%与 80.33%。经比较可发现,所提方案应用于干式变压器与油浸式变压器的准确率均高于其他方法,且具备未知类型故障的辨识能力。说明所提方案能更准确地提取变压器振动信号的特征,且具有更强的适应性和泛化能力。

6 结 论

本文提出一种将 CEEMDAN 与 GCN 相结合的故障诊断算法,实现配电变压器潜伏性故障的诊断与分类。所提改进的 GCN 模型能从多尺度挖掘配电变压器故障信号的深层特征,提高模型的分类准确率。实验验证可见,对于所模拟油浸式变压器故障和干式变压器故障,所提方案的分类准确率分别达到 97.73%和 95.6%,优于文献中的对比方法,充分说明所提方案具备较强的适应性。本文还针对传统模型存在对未知类型故障无法辨识的问题,提出一种峰值因子指标,将未训练过的 BC 短路故障样本输入至模型中,将其标识为独立故障类型,且准确率达到 92.76%。

下一阶段将重点研究算法面对多重混合故障时的辨识能力,并通过改进克服运行工况波动带来的影响。

参考文献

[1] 潘超,陈祥,蔡国伟,等.基于小波包尺度-能量占比的变压器三相不平衡绕组振动特征辨识[J].仪器仪表报,2020,41(4):129-137.
PAN CH, CHEN X, CAI G W, et al. Identification of winding vibration characteristics of three-phase unbalanced transformer based on scale-energy ratio of wavelet packet [J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 129-137.

[2] 史琳芸.基于 ZigBee 的电力变压器无线监控系统监测策略研究[J].国外电子测量技术,2019,38(10):119-123.

SHI L Y. Design of wireless monitoring system for power transformer based on ZigBee [J]. Foreign Electronic Measurement Technology, 2019, 38(10): 119-123.

[3] 汲胜昌,张凡,师愉航,等.基于振动信号的电力变压器机械状态诊断方法研究综述[J].高电压技术,2020,46(1):257-272.
JI SH CH, ZHANG F, SHI Y H, et al. Review on vibration-based mechanical condition monitoring in power transformers [J]. High Voltage Engineering, 2020, 46(1): 257-272.

[4] 赵莉华,丰遥,谢荣斌,等.基于交叉小波的变压器振动信号幅频特征量提取方法[J].高电压技术,2019,45(2):505-511.
ZHAO L H, FENG Y, XIE R B, et al. Amplitude and frequency feature extraction for transformer vibration based on cross-wavelet transform [J]. High Voltage Engineering, 2019, 45(2): 505-511.

[5] SUN J, XING H Y, WU J J. Distributed sea clutter denoising algorithm based on variational mode decomposition [J]. Instrumentation, 2020, 7(3): 23-32.

[6] 李莉,朱永利,宋亚奇.变压器绕组多故障条件下的振动信号特征提取[J].电力自动化设备,2014,34(8):140-146.
LI L, ZHU Y L, SONG Y Q. Feature extraction for vibration signal of transformer winding with multiple faults [J]. Electric Power Automation Equipment, 2014, 34(8): 140-146.

[7] SHANG H, XU J, LI Y, et al. a novel feature extraction method for power transformer vibration signal based on CEEMDAN and multi-scale dispersion entropy [J]. Entropy, 2021, 23(10): 1319.

[8] 马宏忠,弓杰伟,李凯,等.基于 ANSYS Workbench 的变压器绕组松动分析及判定方法[J].高电压技术,2016,42(1):192-199.
MA H ZH, GONG J W, LI K, et al. Analysis and determination method for transformer winding looseness based on ANSYS Workbench [J]. High Voltage Engineering. 2016, 42(1): 192-199.

[9] 武立平,吴强,丰遥,等.基于振动信号 SVM 分类的变压器状态识别[J].高压电器,2019,55(11):232-238.
WU L P, WU Q, FENG Y, et al. State recognition of transformer based on SVM classification of vibration signals [J]. High Voltage Apparatus, 2019, 55(11): 232-238.

[10] 殷作洋,吴肖锋,仲伟坤.基于随机森林的变压器故障识别与实例分析[J].电子测量技术,2020,43(23):63-67.

- YIN Z Y, WU X F, ZHONG W K. Transformer fault recognition based on random forest and case analysis[J]. *Electronic Measurement Technology*, 2020, 43(23): 63-67.
- [11] 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.
- [12] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks [C]. *International Conference on Learning Representations (ICLR)*, 2017.
- [13] ZHANG D, STEWART E, ENTEZAMI M, et al. Intelligent acoustic-based fault diagnosis of roller bearings using a deep graph convolutional network [J]. *Measurement*, 2020, 156, 107585.
- [14] TORRESM E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise [C]. *Proceedings of the 2011 IEEE International Conference on Acoustics, Speech and Signal (ICASSP)*. Prague, Czech Republic, 2011: 4144-4147.
- [15] COLOMINAS M A, SCHLOTTHAUER G, TORRES M E. Improved complete ensemble EMD: A suitable tool for biomedical signal processing [J]. *Biomedical Signal Processing and Control*, 2014, 14: 19-29.
- [16] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. *Advances in Engineering Software*, 2014, 69(7), 46-61.
- [17] 何思名, 袁智勇, 雷金勇, 等. 基于改进灰狼算法的 DG 接入配电网反时限过电流保护定值优化[J]. *电力系统保护与控制*, 2021, 49(18): 173-181.
- HE S M, YUAN ZH Y, LEI J Y, et al. Optimal setting method of inverse time over-current protection for a distribution network based on the improved grey wolf optimization[J]. *Power System Protection and Control*, 2021, 49(18): 173-181.
- [18] 郭振洲, 刘然, 拱长青, 等. 基于灰狼算法的改进研究[J]. *计算机应用研究*, 2017, 34(12): 3603-3606, 3610.
- GUO ZH ZH, LIU R, GONG CH Q, et al. Study on improvement of gray wolf algorithm [J]. *Application Research of Computers*, 2017, 34(12): 3603-3606, 3610.
- [19] 洪翠, 杨华锋, 卢国仪, 等. 基于振动信号 SVM 分类的配变故障识别方法[J]. *仪器仪表学报*, 2016(6): 1299-1308.
- HONG C, YANG H F, LU G Y, et al. Fault identification method for distribution transformer based on SVM classification of vibration signal [J]. *Chinese Journal of Scientific Instrument*, 2016(6): 1299-1308.
- [20] 徐卫, 钟斌, 杜向京, 等. 在运变压器表面不同测点振动特性分析[J]. *高压电器*, 2019, 55(11): 126-132.
- XU W, ZHONG B, DU X J, et al. Vibration characteristics of different measuring points on surface of transformer in operation [J]. *High Voltage Apparatus*, 2019, 55(11): 126-132.
- [21] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE[J]. *Journal of Machine Learning Research*, 2008, 9: 2579-2605.

作者简介



洪翠, 分别在 1994 年、2000 年和 2014 年于福州大学获得学士学位、硕士学位和博士学位, 现为福州大学副教授, 主要研究方向为配电网及其主设备故障诊断。

E-mail: hongcui@fzu.edu.cn

Hong Cui received her B. Sc., M. Sc. and Ph. D. degree from Fuzhou University in 1994, 2000 and 2014, respectively. Now she is an associate professor in Fuzhou University. Her main research interests include fault diagnosis of distribution network and its main equipment.



高伟 (通信作者), 2005 年于福州大学获得学士学位, 2008 年于福州大学获得硕士学位, 2021 年于台湾科技大学获得博士学位, 现为福州大学副教授, 主要研究方向为电力系统及设备故障诊断。

E-mail: gaowei0203@fzu.edu.cn

Gao Wei (Corresponding author) received his B. Sc. degree from Fuzhou University in 2005 and M. Sc. degree from Fuzhou University in 2008 and Ph. D. degree from National Taiwan University of Science and Technology in 2021, respectively. Now he is an associate professor in Fuzhou University. His main research interests include fault diagnosis of power system and equipment.