

DOI: 10.19783/j.cnki.pspc.231278

基于漏磁场和 ICOA-ResNet 的变压器绕组早期故障诊断

刘建锋, 李志远, 周亚茹

(上海电力大学电气工程学院, 上海 200090)

摘要: 针对变压器绕组变形、轻微匝间短路故障诊断准确率低的问题, 提出一种变压器绕组早期故障诊断方法。首先, 利用 ANSYS 仿真软件建立与实验变压器相关参数一致的有限元模型, 分析变压器在绕组发生各种故障的漏磁场分布规律, 并根据这些规律选取合适的故障特征以及光纤漏磁场传感器安装位置。然后, 通过改进长鼻浣熊优化算法(improved coati optimization algorithm, ICOA)寻找残差神经网络(ResNet)的最优超参数, 以此参数构建 ICOA-ResNet 模型, 将所得故障特征量输入模型进行故障诊断。最后, 通过仿真数据和动模实验验证所提出的变压器绕组早期故障诊断模型的可行性。所提模型与支持向量机等 4 种模型相比, 在绕组早期故障诊断上有更高的准确率, 表明所提方法对变压器绕组变形、匝间短路故障诊断的有效性。

关键词: 变压器早期故障诊断; 绕组变形; 漏磁场; 长鼻浣熊优化算法; 残差神经网络; 超参数优化

Transformer windings based on leakage field and ICOA-ResNet early fault diagnosis

LIU Jianfeng, LI Zhiyuan, ZHOU Yaru

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

Abstract: There is low diagnostic accuracy of transformer winding deformation and slight inter-turn short circuit fault diagnosis. Thus an early fault diagnosis method for transformer windings is proposed. First, ANSYS simulation software is used to establish a finite element model consistent with the relevant parameters of the experimental transformer. It also analyzes the distribution law of the leakage magnetic field of the transformer in the winding faults, and selects the appropriate fault characteristics and the installation position of the optical fiber leakage magnetic field sensor according to these laws. Then, the optimal hyperparameters of residual networks (ResNet) are found by improved coati optimization algorithm (ICOA), and the ICOA-ResNet model is constructed based on these parameters. The fault characteristics are input into the model for fault diagnosis. Finally, the feasibility of the proposed early fault diagnosis model for transformer windings is verified by simulation data and dynamic model experiments. Compared with four other models such as the support vector machine, the proposed model has higher accuracy in early fault diagnosis. This shows that the proposed method is effective in transformer winding deformation and inter-turn short circuit fault diagnosis.

This work is supported by the National Natural Science Foundation of China (No. 51777119).

Key words: transformer early fault diagnosis; winding deformation; leakage magnetic field; coati optimization algorithm; residual networks; hyperparameter optimization

0 引言

变压器在运行过程中受到短路电流冲击可能导致绕组发生形变, 在累积效应的作用下极易发展为绕组匝间故障^[1-2]。而在绕组变形或匝间短路初期, 变压器内部绕组故障并未对变压器运行产生巨大影响^[3], 此时由于差动信号较小, 传统差动保护难以

有效动作, 如果任其在这种绕组故障状态下长期运行, 故障可能会进一步发展为严重故障, 影响电力系统的安全稳定运行^[4]。目前变压器故障检测方法主要有振动信号法^[5]、频率响应分析法^[6]、油中溶解气体法^[7]等, 振动信号法在敏感特征的提取上较为乏力, 频率响应分析法在诊断绕组轻微故障时因其幅频特性曲线变化较小容易导致漏检, 油中溶解气体法在进行差异化评价时缺少客观依据, 容易导致变压器状态误判。以上方法在绕组早期故障诊断

基金项目: 国家自然科学基金项目资助(51777119)

时都存在一定的局限性, 而通过研究发现, 当变压器绕组出现早期故障隐患时, 绕组附近的漏磁场分布会发生改变且有一定规律可循^[8], 这为通过检测漏磁场分布变化来进行早期故障诊断提供了新的研究方法。

文献[9-10]利用仿真软件对变压器绕组不同状态下的漏磁场进行研究, 总结了部分绕组故障状态下漏磁场的分布规律和特征, 提出了漏磁传感器布置方案。但以上研究只是对某一故障程度下漏磁场分布进行了分析, 并未研究漏磁场随着故障严重程度变化的规律, 也没有进行相关的实验验证。

在故障诊断方面, 基于机器学习变压器故障诊断的方法有支持向量机(support vector machine, SVM)^[11]、极限学习机^[12]、神经网络^[13]等, 支持向量机为浅层结构, 特征提取能力弱; 极限学习机稳定性较差, 识别精度易受权值和参数的影响; 深度神经网络理论上分类效果较好, 但由于其结构层次较深, 容易产生梯度消失或梯度爆炸的问题。残差神经网络的出现改善了梯度不稳定和网络退化的情况^[14], 使深度网络性能得到了进一步提升。但由于任何神经网络模型都无法对所有数据集进行最佳泛化, 因此在对新的数据集进行深度学习时, 必须选取合适的超参数^[15], 其选取是否合适决定了最终结果的好坏。目前手动选择超参数是根据经验或多次测试选择合适的参数, 可能因主观因素而使模型陷入局部最优和过拟合^[16]。因此有效的超参数寻优方法对提升神经网络的性能至关重要。相比于蚁群优化算法、灰狼优化算法、鲸类优化算法, 长鼻浣熊优化算法有更强的寻优能力^[17], 可用于超参数的寻优。

本文按实验室变压器的相关参数搭建了变压器有限元模型, 研究了变压器在绕组变形、匝间短路故障情况下的漏磁场分布特性, 并分析了各类故障在不同严重程度下的漏磁场分布规律, 选取了 6 种故障特征类型作为诊断依据, 并提取故障特征量输入残差神经网络进行训练。然后通过改进长鼻浣熊优化算法获取残差神经网络的最佳超参数, 并建立 ICOA-ResNet 模型进行变压器绕组早期故障诊断, 最后通过动模实验验证所提模型在变压器绕组早期故障诊断方面的有效性。

1 变压器绕组故障漏磁场分析及特征选择

1.1 变压器漏磁场计算及有限元模型的搭建

变压器漏磁场是一个含有多介质、非线性的三维瞬态涡流场问题, 工程上可使用分区法对求解区域进行解析, 同时利用单重傅里叶法对变压器漏磁场求解区域进行简化, 求解出矢量磁位 A ^[18]。

$$B = \nabla \times A \quad (1)$$

式中: B 为磁感应强度; ∇ 为哈密尔顿算符。

进一步求解区域内相应位置对应的轴向磁感应强度、径向磁感应强度^[18], 分别为

$$\begin{cases} B_z = -\frac{\partial A}{\partial x} \\ B_x = \frac{\partial A}{\partial z} \end{cases} \quad (2)$$

式中: B_z 为沿 z 轴方向的磁感应强度; B_x 为沿 x 轴方向的磁感应强度。

按照动模实验室所用三相三柱干式变压器在 ANSYS 软件中搭建了变压器三维有限元模型, 如图 1 所示, 变压器结构参数如表 1 所示、变压器电气参数如表 2 所示。

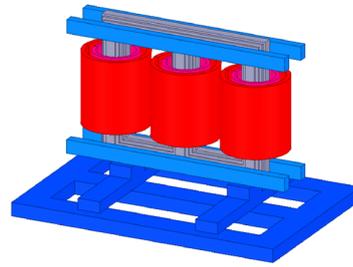


图 1 变压器三维有限元模型

Fig. 1 Three-dimensional finite element model of transformer

表 1 变压器结构参数

Table 1 Transformer structure parameter

参数名称	数值	参数名称	数值
铁芯直径/mm	115	铁芯窗高/mm	430
铁芯中心距/mm	320	铁轭中心距/mm	530
高压绕组高度/mm	320	低压绕组高度/mm	320
高压绕组内径/mm	128.5	低压绕组内径/mm	87.5
高压绕组外径/mm	151	低压绕组外径/mm	107
高压绕组匝数	201	低压绕组匝数	139

表 2 变压器电气参数

Table 2 Transformer electrical parameter

参数名称	数值	参数名称	数值
额定容量/kVA	50	最高电压/kV	3.6
额定电压/kV	1/0.4	空载电流/A	2.4838
额定电流/A	28.87/72.17	空载损耗/W	257.4
额定频率/Hz	50	铁芯材料	30Q130

1.2 变压器绕组故障的漏磁场分布特性分析

本文考虑了高压侧绕组发生典型故障的情况, 设置故障如下:

1) 故障发生于距绕组下端 255 mm 高度的局部径向鼓包, 形变程度分别为 5%、10%、15%、20%、

25%、35%、50%;

2) 故障发生于距绕组下端 160 mm 高度的局部径向鼓包, 形变程度与 1) 相同;

3) 故障发生于绕组上端的单端轴向压缩, 形变程度分别为 1%、5%、8%、10%、15%、20%;

4) 故障发生于绕组双端的轴向压缩, 形变程度与 3) 相同;

5) 故障发生于距绕组下端约 176 mm 高度的匝间短路, 短路程度分别为 0.498%、0.995%、1.493%、1.99%。

仿真所取的观测线 line1 位于高压绕组外侧, 如图 2 所示。

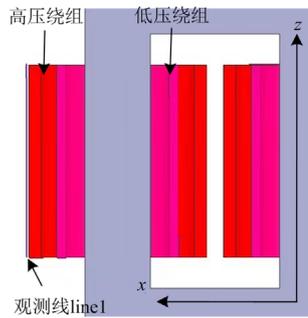


图 2 观测线 line1 位置

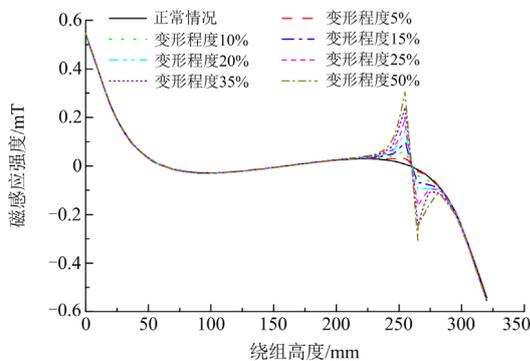
Fig. 2 Position of the observation line1

1.2.1 高压侧绕组局部径向形变

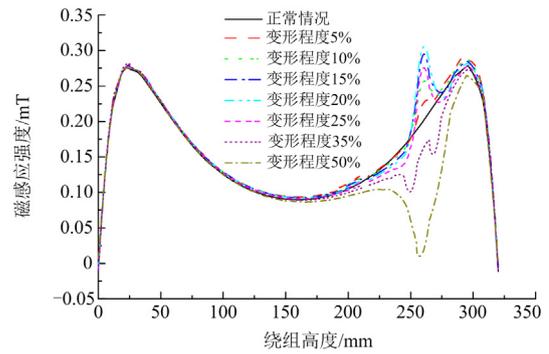
当高压侧绕组 255 mm 高度发生不同程度的局部鼓包时, line1 上的漏磁场分布特性如图 3 所示。

当变压器正常运行时, 径向磁感应强度和轴向磁感应强度分别呈中心对称和轴对称, 而当高压侧绕组发生局部鼓包时, 这种对称性被破坏。对于非故障区域, 其径向磁感应强度和轴向磁感应强度几乎没有发生变化, 漏磁场分布也基本不变。

在鼓包及其附近区域, 漏磁场分布发生了一定改变, 且随着变形程度的加剧, 漏磁场分布发生畸变的区域也相应扩大。在故障点两侧区域的径向磁



(a) 径向磁感应强度 B_r



(b) 轴向磁感应强度 B_z

图 3 不同故障程度局部鼓包漏磁场分布

Fig. 3 Local bulge leakage magnetic field distribution with different fault degree

感应强度随变形程度加剧而增大。对于轴向磁感应强度, 在绕组形变程度达到 25% 之前, 鼓包位置一端的磁感应强度幅值随变形程度增加而减小, 另一端则随变形程度增加而增大。在绕组形变程度超过 25% 之后, 磁感应强度幅值随变形程度加剧而急剧减小。

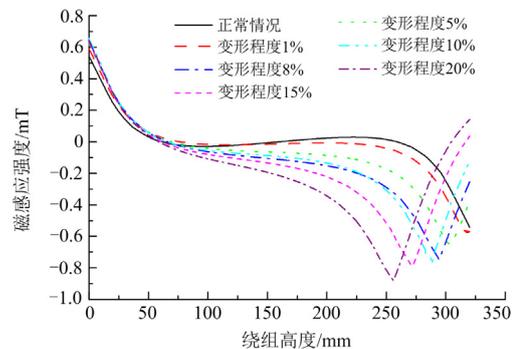
当高压侧绕组 160 mm 高度发生不同形变程度的局部鼓包时, line1 上的漏磁场分布特性与上述基本相同, 只是漏磁场分布畸变位置发生于 160 mm 高度附近, 但径向磁感应强度和轴向磁感应强度仍分别呈中心对称和轴对称。

1.2.2 高压侧绕组单端轴向压缩

当高压侧绕组上端发生不同程度的轴向压缩时, line1 上的漏磁场分布特性如图 4 所示。

当绕组发生单端轴向压缩时, line1 上的漏磁场分布对称性被破坏。随着形变程度的增加, 漏磁场畸变程度也越来越大。

对于径向磁感应强度来说, 沿 line1 路径上的径向磁感应强度大部分都发生了改变, 只有远离形变部分的区域变化不大, 径向磁感应强度变化最大的地方出现在形变发生的位置。对轴向磁感应强度来



(a) 径向磁感应强度 B_r

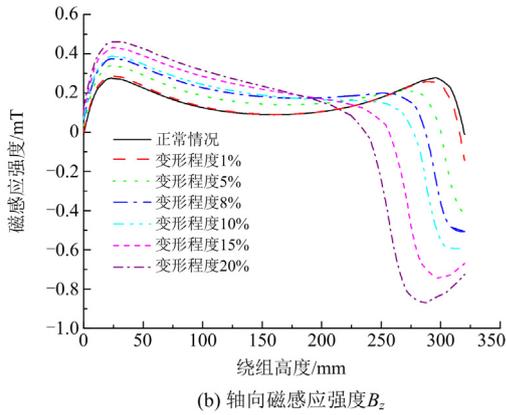


图 4 不同故障程度单端轴向压缩漏磁场分布

Fig. 4 Single-end axial compression leakage field distribution with different fault degree

说,沿观测线路径上的轴向磁感应强度都发生了改变,轴向磁感应强度变化最大的地方出现在形变处附近。

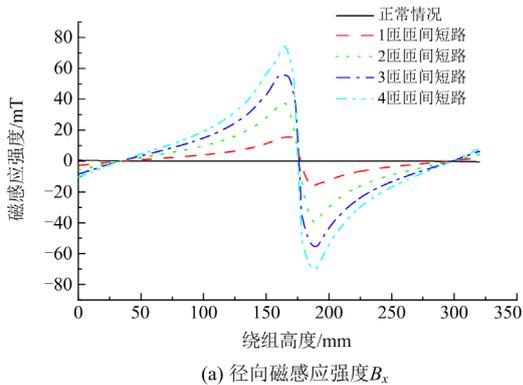
当绕组发生双端轴向压缩时,沿观测线路径上的轴向磁感应强度几乎全都发生了改变,两端形变处磁感应强度变化最大。

1.2.3 高压侧绕组匝间短路

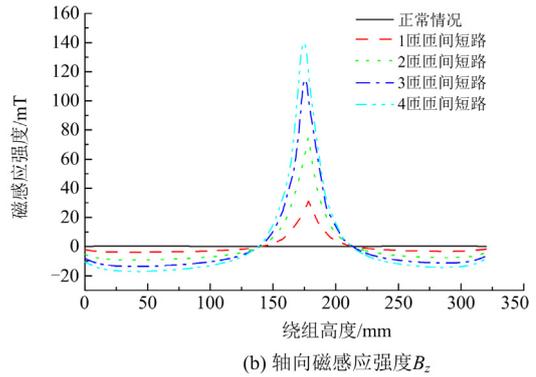
仿真设置短路起始时间为 20 ms,短路持续时间为 120 ms,其中在短路发生后 12 ms 时短路电流达到最大,此时观测线上的漏磁场分布如图 5 所示。

当绕组发生匝间短路时,沿观测线路径上的径向磁感应强度和轴向磁感应强度都发生了显著的改变,即使在远离匝间短路的区域也有较为明显的变化,而且越靠近匝间短路的地方漏磁场畸变程度越大。这是因为发生匝间短路时,短路匝和正常匝之间会形成一个短路环,在短路环中的电流可以达到正常额定电流的数十倍^[20]。当短路匝数增多时,短路环内的电流也越来越大,在漏磁场上的表现为随着短路匝数变多,磁感应强度变化较大。

对于变压器空载合闸工况,各测点所采集的波形经滤波处理后,波形仍然处于不对称状态,其形



(a) 径向磁感应强度 B_r



(b) 轴向磁感应强度 B_z

图 5 不同故障程度匝间短路漏磁场分布

Fig. 5 Inter-turn short-circuit leakage field distribution with different fault degree

状与正常运行下的波形有较大差异,但漏磁场整体分布基本仍是对称的^[21],对此可以通过相关系数和不对称度对该工况进行甄别。

1.3 传感器布置及故障特征选择

由上述分析可以得到各故障的漏磁场分布特性规律如下。

1) 对于绕组局部鼓包,只有在鼓包及其附近位置的漏磁场分布才有明显变化,其中鼓包点附近区域的磁感应强度随变形程度的加剧而增大,其余位置的漏磁场分布基本不变,当发生非绕组中部鼓包时,漏磁场分布曲线的对称性被破坏。

2) 对于轴向压缩,沿观测线的漏磁场分布相对正常状态发生了大范围变化,在形变发生处变化最大,且随着变形程度的加剧而增大,只有远离形变处的漏磁场分布变化不大,漏磁场分布曲线的对称性被完全破坏。对于双端轴向压缩,漏磁场分布曲线是否具有对称性与双端压缩程度是否相同有关。

3) 对于匝间短路,观测线上的漏磁场分布完全改变,且变化程度是以上所有故障类型中最大的,漏磁场分布曲线是否具有对称性与匝间短路是否发生在绕组中部有关。

基于以上规律和本文实验变压器的尺寸,光纤漏磁场传感器布置于 line1 上,5 个传感器等距离安置。故障特征选取以下 6 种类型。

设 $B_n = \{b_{01}, b_{02}, \dots, b_{0n}\}$ 为变压器正常运行时的漏磁场曲线, $B_f = \{b_1, b_2, \dots, b_n\}$ 为变压器发生故障时的漏磁场曲线。其中, $b_{0\alpha}$ 、 b_α 分别为正常运行与故障时漏磁曲线中第 α 个采样点。

1) Hausdorff 距离

Hausdorff 距离 (H_a) 可以判断两条曲线的波形和幅值差异^[22]。故障状态下漏磁场曲线与正常状态下漏磁场曲线之间的 Hausdorff 距离会随着故障严

重程度的增加而增大, 所以 Hausdorff 距离可以衡量漏磁场曲线在不同情况下的相似度。其表达式为

$$H_a = \max\{h(B_n, B_f), h(B_f, B_n)\} \quad (3)$$

式中, $h(B_n, B_f)$ 、 $h(B_f, B_n)$ 分别为两条漏磁场曲线的单向 Hausdorff 距离, 计算式为

$$h(B_n, B_f) = \max_{b_{0\alpha} \in B_n} \left\{ \min_{b_\gamma \in B_f} \|b_{0\alpha}, b_\gamma\| \right\} \quad (4)$$

$$h(B_f, B_n) = \max_{b_\gamma \in B_f} \left\{ \min_{b_{0\alpha} \in B_n} \|b_{0\alpha}, b_\gamma\| \right\} \quad (5)$$

式中, b_γ 为故障时漏磁场曲线中第 γ 个采样点。

2) 相关系数

相关系数 (C_C) 可以很好地反映两条曲线的形状差异^[23], 而绕组不对称故障, 其故障处测点幅值会发生变化, 相位相对于正常状态也有一定变化, 所以相关系数对于故障程度较小的不对称故障有较强的分辨能力。

$$C_C = \frac{\sum_{\alpha=1}^n b_{0\alpha} b_{\alpha}}{\sqrt{\sum_{\alpha=1}^n b_{0\alpha}^2 \sum_{\alpha=1}^n b_{\alpha}^2}} \quad (6)$$

正常运行状态下两条漏磁场曲线的相关系数一般在数值 1 附近, 当变压器绕组发生形变、匝间短路时, 各测点相关系数相对于正常运行状态变小, 若二者波形差异很大, 其值可低至小数点后两位到三位。

3) 对数误差绝对值和

对数误差绝对值和 (A_{SLE}) 可用于衡量两条曲线的幅值差异, 能够弥补相关系数对于两条形状相似、幅值不同的曲线判别能力较弱的缺点^[24]。

$$A_{SLE} = \frac{1}{n} \sum_{\alpha=1}^n |b_{0\alpha} - b_{\alpha}| \quad (7)$$

4) 最大偏差

最大偏差 (M_{AX}) 用于描述两条曲线中数据之间的最大变动范围。针对绕组局部鼓包漏磁分布与正常状态漏磁分布区别不大的特点, 可通过最大偏差来描述故障漏磁场曲线与正常漏磁场曲线之间的极端偏差大小, 以达到区分二者的目的。

$$M_{AX} = \sqrt{\max(b_{\alpha} - b_{0\alpha})} \quad (8)$$

5) 不对称度

变压器在正常工况下, 漏磁场在空间中的分布具有对称性。但当绕组发生不对称故障时, 这种对称性被破坏, 故障越严重, 漏磁场分布越不对称。故引入不对称度 (η) 这一故障特征^[25]。

$$\begin{cases} \eta_{1-5} = \frac{\sum |B(x_1) - B(x_5)|}{\sum |B(x_1) + B(x_5)|} \\ \eta_{2-4} = \frac{\sum |B(x_2) - B(x_4)|}{\sum |B(x_2) + B(x_4)|} \end{cases} \quad (9)$$

式中: η_{1-5} 、 η_{2-4} 分别表示第 1 个与第 5 个测点, 第 2 个与第 4 个测点之间的不对称度; $B(x_q)$ 表示第 q 个测点测量的漏磁场曲线。处于正常运行状态下的不对称度是一个很小的值, 发生不对称故障时该值会变得相对很大。不对称度不能反映故障发生的大致位置, 但可以作为判断绕组是否发生不对称故障的辅助指标。

6) 分布差异度

当故障发生于绕组上部分时, 4、5 测点所采集的各采样点与正常状态的磁感应强度作差后求和大于 1、2 号测点; 当故障发生于下部分时, 4、5 测点所采集的各采样点与正常状态的磁感应强度作差后求和小于 1、2 号测点。分布差异度 (D) 可以反映绕组非对称故障发生的大致位置^[26]。

$$\begin{cases} D_{1-5} = \sum_{\alpha=1}^n |b_{\alpha}^1 - b_{0\alpha}^1| - \sum_{\alpha=1}^n |b_{\alpha}^5 - b_{0\alpha}^5| \\ D_{2-4} = \sum_{\alpha=1}^n |b_{\alpha}^2 - b_{0\alpha}^2| - \sum_{\alpha=1}^n |b_{\alpha}^4 - b_{0\alpha}^4| \end{cases} \quad (10)$$

式中: D_{1-5} 、 D_{2-4} 分别表示第 1 个与第 5 个测点, 第 2 个与第 4 个测点之间的分布差异度; $b_{0\alpha}^p$ 、 b_{α}^p 分别为第 p 个测点所采集的正常运行时与故障时漏磁曲线中第 α 个采样点。取正常状态的分布差异度的绝对值为阈值 D_{set1} 、 D_{set2} 。当 D_{1-5} 、 D_{2-4} 的绝对值大于阈值时, 说明绕组可能发生不对称故障, 若 D_{1-5} 、 D_{2-4} 大于 0, 则故障发生于绕组下部; 若 D_{1-5} 、 D_{2-4} 小于 0, 则故障发生于绕组上部。

当变压器为非对称绕组时, 则将不对称度与分布差异度置 0。

2 基于 ICOA 的残差神经网络模型

在选取合适的故障特征后, 本文通过构建 ICOA-ResNet 模型进行变压器绕组早期故障诊断。

2.1 改进长鼻浣熊优化算法(ICOA)

2.1.1 长鼻浣熊优化算法

长鼻浣熊优化算法(coati optimization algorithm, COA)较为出色的寻优能力可应用于神经网络超参数寻优。该算法模拟了长鼻浣熊的两种自然行为策略来进行超参数寻优。在进行变压器绕组早期故障

诊断时,可利用长鼻浣熊优化算法,选择残差神经网络的超参数。具体描述如下。

1) 种群初始化

在整个寻优空间里随机初始化种群,表示为

$$x_{i,j} = l_j + R \cdot (u_j - l_j) \quad (11)$$

式中: $x_{i,j}$ 为第 i 个长鼻浣熊在第 j 维的位置; l_j 为第 j 维变量的下边界; u_j 为第 j 维变量的上边界; R 为[0,1]之间的随机数。

2) 攻击与捕食(勘察阶段)

第一阶段中一半的长鼻浣熊袭击一只鬣蜥,当鬣蜥改变位置后,剩余的长鼻浣熊攻击并捕食它。其中一半长鼻浣熊位置的表达式为

$$x_{i,j}^{P1} = x_{i,j} + R \cdot (I_j^G - I \cdot x_{i,j}) \quad (12)$$

式中: $x_{i,j}^{P1}$ 为第 i 个长鼻浣熊在第 j 维的新位置; $i=1,2,\dots,N/2$; I 为从集合 {1,2} 中随机选取的整数; I_j^G 为鬣蜥的原位置。

剩余的长鼻浣熊在搜索空间开始移动

$$x_{i,j}^{P1} = \begin{cases} x_{i,j} + R \cdot (I_j^{G,\text{new}} - I \cdot x_{i,j}), & F_1^G < F_i \\ x_{i,j} + R \cdot (x_{i,j} - I_j^{G,\text{new}}), & \text{else} \end{cases} \quad (13)$$

式中: $I_j^{G,\text{new}}$ 为鬣蜥的新位置; F_i 为更新位置之前的目标函数; F_1^G 为鬣蜥改变位置后的目标函数,其中 $i=1+N/2,2+N/2,\dots,N$ 。

判断更新后的位置是否优化了目标函数,如果优化了目标函数则更新位置,否则保持原位置不变。

3) 逃脱捕猎者(开发阶段)

第二阶段中长鼻浣熊在遭遇捕猎者时会逃离到安全位置。此时在每只长鼻浣熊附近生成一个随机位置。

$$x_{i,j}^{P2} = x_{i,j} + (1-2R) \cdot (l_j^{\text{local}} + R \cdot (u_j^{\text{local}} - l_j^{\text{local}})) \quad (14)$$

式中: $x_{i,j}^{P2}$ 为第 i 个长鼻浣熊在第 j 维的新位置; l_j^{local} 为当前位置的下边界; u_j^{local} 为当前位置的上边界。

判断更新后的位置是否优化了目标函数,如果优化了目标函数则更新位置,否则保持原位置不变。

在经过两个阶段更新了搜索空间中所有长鼻浣熊的位置后,算法完成本次迭代。然后 COA 进行下一次迭代直到最后一次迭代完成,此时最优解作为输出返回。

2.1.2 长鼻浣熊优化算法的改进

1) Circle 混沌映射初始化种群

标准 COA 中初始化种群是随机的,这会使种群多样性偏低,算法容易陷入局部最优,影响后期全局搜索能力。混沌映射可以生成具有非线性和不可预测性的序列,能够增加种群的随机性和多样

性^[27]。本文采用 Circle 混沌映射来初始化种群,以提高算法的寻优精度。Circle 混沌映射的表达式为

$$x_{k+1} = \text{mod}[x_k + b - \frac{a}{2\pi} \sin(2\pi x_k), 1] \quad (15)$$

式中: mod 为取余函数; a 取 0.5; b 取 0.2; x_k 、 x_{k+1} 为映射函数值。

2) 引入 Levy 飞行策略

在 COA 的第二阶段,后期容易陷入局部最优,为此引入 Levy 飞行策略来改善该情况。Levy 飞行是一种随机游走策略,能很好地均衡局部开发与全局搜索能力。

$$\begin{cases} L = \frac{\mu}{|\nu|^{1/\beta}}, \mu \sim N(0, \sigma_\mu^2), \nu \sim N(0, \nu_\mu^2) \\ \sigma_\mu = \left(\frac{\Gamma(1+\beta) \times \sin(\pi\beta/2)}{\Gamma((1+\beta)/2) \times \beta \times 2^{(\beta-1)/2}} \right) \end{cases} \quad (16)$$

式中: L 为飞行步长; β 取 1.5; $\Gamma(\cdot)$ 为 Gamma 函数; μ 、 ν 服从正态分布; ν_μ 取 1。

将 Levy 飞行策略引入 COA,更新式(14)为

$$x_{i,j}^{P2} = x_{i,j} + (1-2R) \cdot (l_j^{\text{local}} + R \cdot (u_j^{\text{local}} - l_j^{\text{local}})) \cdot L \quad (17)$$

2.1.3 改进算法性能测试

本文采取表 3 所示的基准测试函数进行改进前后的算法性能测试。表 3 中, f_1 、 f_2 为单模态测试函数,用来评估优化算法的局部搜索能力, f_3 为多模态测试函数,用来评估优化算法的全局搜索能力和收敛速度。

表 3 基准测试函数

Table 3 Benchmark function

函数表达式	维度	取值范围	理论值
$f_1(x) = \sum_{i=1}^n x_i^2$	30	[-100,100]	0
$f_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30	[-10,10]	0
$f_3(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i)] + 10n$	30	[-6,6]	0

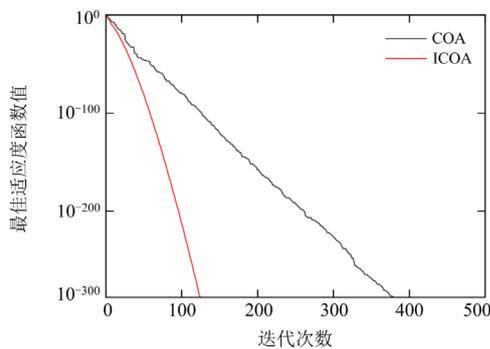
由表 4 可见,对于 f_1 、 f_2 单模态测试函数,ICOA 的最优值均达到理论最优值,且平均值与标准差均小于 COA,表明了 ICOA 相较于 COA 具有更强的局部搜索能力;对于 f_3 多模态测试函数,二者的最优解均达到理论最优值,但 ICOA 平均值与标准差均小于 COA,这表明了 ICOA 相较于 COA 有更强的全局搜索能力。

由图 6 可见,相对于 COA,ICOA 在求解 3 种基准函数时具有更快的收敛速度和更高的寻优精度。综上,ICOA 比 COA 具有更强的局部搜索能力和全局搜索能力,在保证收敛速度的同时拥有更好的精度。

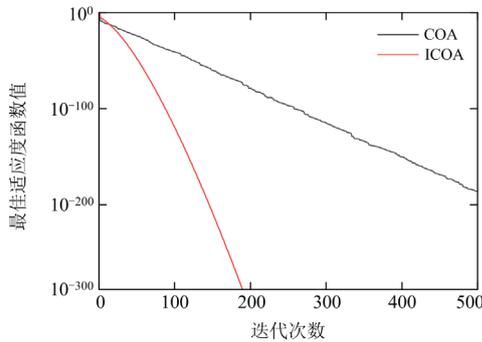
表 4 算法性能比较

Table 4 Algorithm performance comparison

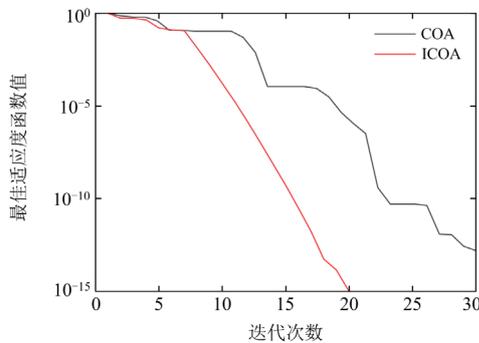
基准函数	评价指标	COA	ICOA
$f_1(x)$	最优解	0	0
	平均值	0.004 53	7.605×10^{-7}
	标准差	0.0974	1.6053×10^{-5}
$f_2(x)$	最优解	9.833×10^{-187}	0
	平均值	0.0025	2.2603×10^{-4}
	标准差	0.0377	0.0039
$f_3(x)$	最优解	0	0
	平均值	0.1393	1.0463×10^{-7}
	标准差	1.6802	2.0944×10^{-6}



(a) 基准函数 f_1 收敛曲线



(b) 基准函数 f_2 收敛曲线



(c) 基准函数 f_3 收敛曲线

图 6 基准函数收敛曲线

Fig. 6 Benchmark function convergence curve

2.2 ICOA-ResNet 模型的建立

2.2.1 残差神经网络

卷积神经网络(convolutional networks, CNN)在处理二维图像上有很大的优势,适用于图像分类。但随着网络层数的加深会出现两个问题:一是精度趋于饱和和无法提升,然后迅速退化;二是会出现梯度消失。

残差神经网络引入 Residual 结构和 Batch Normalization 层改善了网络退化和梯度消失的情况。Residual 结构的特点在于引入了 shortcut 连接方式,因为 shortcut “快捷连接”的存在,使网络在反向传播时,可以通过 shortcut 将梯度传向更前的网络层,从而改善网络退化的情况,ResNet50 两个基本的残差块如图 7 所示,本文网络模型以 ResNet50 为基本结构。

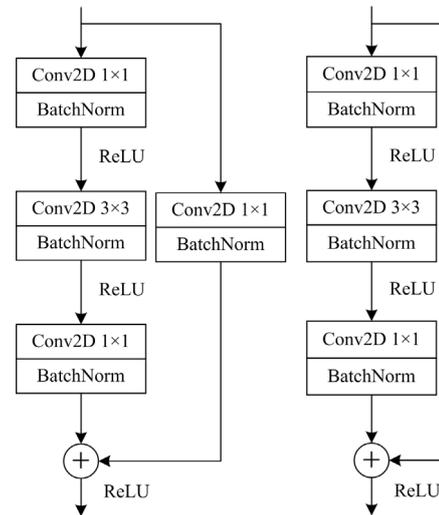


图 7 卷积残差块与恒等残差块

Fig. 7 Convolutional residual block and identity residual block

2.2.2 ICOA-ResNet 模型的构建

由于对任意一个 CNN 模型都无法对所有数据集进行最佳泛化,所以将 CNN 模型应用于一个新数据集前,都必须选取一组合适的超参数^[28]。作为 CNN 衍生出来的 ResNet 在应用于新数据集时同样也要选择合适的超参数,但选取合适的超参数非常困难,人为手动选择超参数会花费大量的精力和时间,且最终结果也不能得到保证。故本文提出了一种改进浣熊优化算法与残差神经网络结合的分类模型,简称 ICOA-ResNet 模型。

在 ICOA-ResNet 模型中采用 ICOA 算法对 ResNet 网络进行超参数优选,ICOA 的本质在于获取最佳目标函数及其种群位置,对于模型而言,考察的是它对陌生数据集的预测能力,因此不选择训

训练集的损失函数作为目标函数。测试集一般用来评估模型性能，所以不宜使用测试集来选取超参数。验证集可以看作一种特殊的训练集，它有助于获取合适的超参数，故选择验证集的损失函数作为目标函数。由于所设计的模型网架结构已经固定，所以寻优超参数选为初始学习率、批处理大小、优化器(Adam, SDG, RMSprop)。

3 基于 ICOA-ResNet 的变压器绕组早期故障诊断模型

为实现变压器绕组早期故障的诊断分类，本文提出了基于 ICOA-ResNet 的变压器绕组早期故障诊断模型。

首先获取 5 个测点的磁感应强度数据，将数据按 6 种故障特征类型转化为特征量。然后将各组特征量输入 ResNet 中，同时利用 ICOA 对残差神经网络进行超参数寻优，以提高模型故障诊断的准确率，得到 ResNet 的最优模型。最后构建变压器绕组早期故障诊断模型。

本文将变压器模型分为 10 种运行状态，各编码如表 5 所示。

表 5 变压器运行状态编码

Table 5 Transformer operating state code

编号	变压器状态	编码
0	下端轴向压缩	(0,0,0,0,0,0,0,0,0,1)
1	上端轴向压缩	(0,0,0,0,0,0,0,0,1,0)
2	双端轴向压缩	(0,0,0,0,0,0,0,1,0,0)
3	绕组下部匝间短路	(0,0,0,0,0,0,1,0,0,0)
4	绕组中部匝间短路	(0,0,0,0,0,1,0,0,0,0)
5	绕组上部匝间短路	(0,0,0,0,1,0,0,0,0,0)
6	正常运行	(0,0,0,1,0,0,0,0,0,0)
7	绕组下部局部鼓包	(0,0,1,0,0,0,0,0,0,0)
8	绕组中部局部鼓包	(0,1,0,0,0,0,0,0,0,0)
9	绕组上部局部鼓包	(1,0,0,0,0,0,0,0,0,0)

基于 ICOA-ResNet 的变压器绕组早期故障诊断模型流程如下：

- 1) 将 5 个测点所测的径向磁感应强度和轴向磁感应强度作为故障诊断的原始数据；
- 2) 将原始数据按 6 种故障特征类型转化为 49 个特征量，最后一个特征量为 0；
- 3) 将特征量归一化后构造为 7×7 特征矩阵，并转为灰度图像，一张灰度图像即为一个样本；
- 4) 将灰度图像预处理后划分为训练集、验证集、测试集；
- 5) 选取 ICOA 的种群规模、最大迭代次数、搜索空间的上下边界，并对种群进行初始化；

6) 将种群初始化后的每个位置作为超参数输入到 ResNet 中进行训练，得到每个位置的目标函数，ICOA 根据目标函数值不断更新种群位置和最优解，直到完成所有迭代，此时输出最佳超参数；

7) 将最佳超参数输入 ResNet 进行训练，建立变压器绕组早期故障诊断模型；

8) 利用测试集进行变压器绕组早期故障诊断，输出故障类型。

4 算例分析及动模验证

4.1 算例分析

由上文可知，本文考虑了高压侧绕组的 10 种运行状态，并对各运行状态编码。仿真样本数据 1060 组，变压器每种运行状态的样本各 106 组，其中 850 组用于训练集和验证集，210 组用于测试集，每组样本包含 5 个测点所测得的径向磁感应强度和轴向磁感应强度的数据。

为验证利用 ICOA-ResNet 进行变压器绕组早期故障诊断的优越性，将模型与 SVM、反向传播神经网络(backpropagation neural network, BPNN)、CNN、ResNet50 进行对比，评价指标为 Accaracy、F₁-Score、G-mean。

Accaracy 即准确率，指对于给定的测试数据集，正确分类的样本数与总样本数之比；F₁-Score 为综合评价指标，指精准度(Precision)与召回率(recall)的加权调和平均值，其值越接近于 1，模型特征提取能力越强，评估性能越好；G-mean 为精准度与召回率的几何平均值，其值越高模型性能越好。

ICOA 设定种群数量为 20，最大迭代次数为 50 次，初始学习率寻优范围为[0.000 01, 0.001]，批处理大小一般取 2 的 n 次方，n 的取值范围为[2, 7]。对于本数据集寻优后的超参数，初始学习率为 0.000 195 24，取 0.0002，批处理大小取 16，优化器选择为 Adam，训练 100 次。

其他模型参数：ResNet50 初始学习率为 0.000 01，批处理大小为 32，优化器为 Adam；CNN 初始学习率为 0.001，批处理大小为 16，优化器为 SGD，网络结构为 2 个卷积层和 2 个池化层，卷积层的卷积核大小为 3×3，步长为 1，激活函数为 ReLU，输出通道数分别为 32、64，然后经最大池化层输入一个全连接层，全连接层包含 128 个神经元，最后由 softmax 层输出；BPNN 的学习率为 0.01，训练次数 100，隐藏层节点数为 20；SVM 的核函数为径向基，其中惩罚因子为 10，核参数为 0.5。

图 8 为 ICOA-ResNet 与 ResNet50 在训练集上前 50 轮的损失函数，可以看出 ICOA-ResNet 模型

收敛速度更快, 最终收敛效果更好, 即模型的训练效果更好。

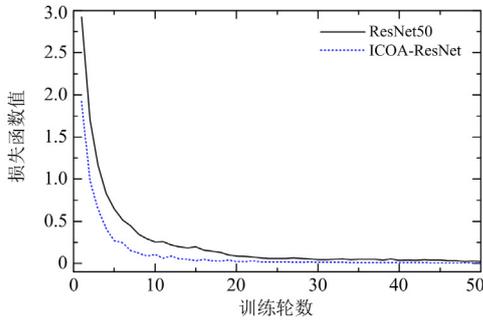


图 8 随训练次数变化的损失函数

Fig. 8 Loss function varying with the number of training

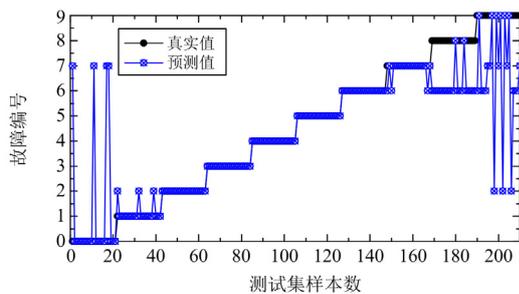
表 6 为各模型最终故障诊断结果, 由表 6 可以看出, 本文模型各项评价指标均高于其他模型, 准确率达到 98.57%。SVM 因其浅层结构, 特征提取能力较弱, 因此诊断情况较差, 故综合评价指标和 G-mean 低于 90%, ResNet50 为深层网络结构, 诊断情况明显优于浅层网络 BPNN、CNN, ICOA-ResNet 在优化超参数后诊断情况优于 ResNet50。

表 6 不同模型的故障诊断结果

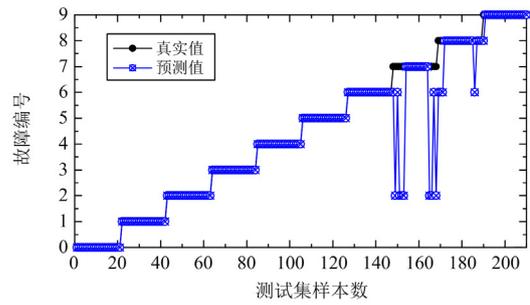
Table 6 Fault diagnosis results of different models

故障诊断模型	Accaracy	F ₁ -Score	G-mean
SVM	79.05	83.57	83.71
BPNN	92.85	93.64	93.65
CNN	93.81	94.40	94.41
ResNet50	97.62	97.74	97.75
ICOA-ResNet	98.57	98.60	98.60

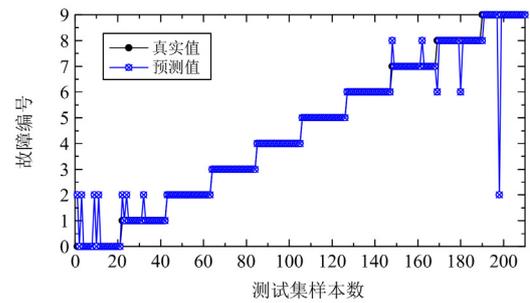
图 9 为不同模型的诊断情况, 可以看出, 本文模型的分类效果最好, 除了对绕组轻微局部鼓包故障存在误判, 对绕组其他故障类型的分类效果非常良好。从各个模型的分类情况来看, 绕组局部鼓包被误判为正常情况的几率最高, 被误判为其他状态的几率也存在, 但相对较小。对于单端轴向压缩、双端轴向压缩、匝间短路等故障, 残差神经网络模



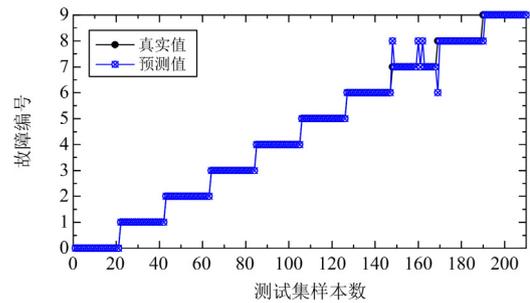
(a) SVM模型诊断结果



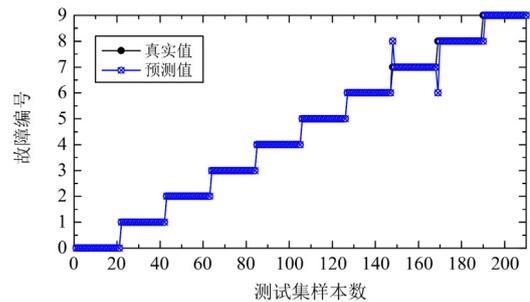
(b) BPNN模型诊断结果



(c) CNN模型诊断结果



(d) ResNet50模型诊断结果



(e) ICOA-ResNet模型诊断结果

图 9 不同模型的诊断情况

Fig. 9 Diagnosis of different models

型基本都能正确分类, 说明本文模型能够较好地绕组大多数故障类型进行诊断。

4.2 动模验证

为检验所提方法在面对现实变压器绕组故障诊断的可行性, 采用动模实验进行验证, 动模实验系统

接线如图 10 所示。实验室变压器及光纤磁场测量系统如图 11 所示。变压器低电压侧带纯阻性负载 28 Ω。

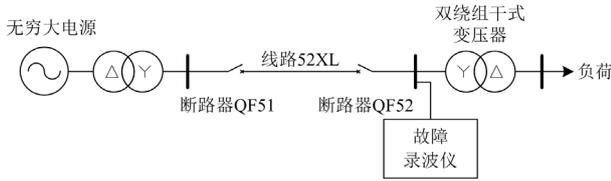


图 10 动模实验室一次系统接线

Fig. 10 Dynamic modeling lab primary system wiring

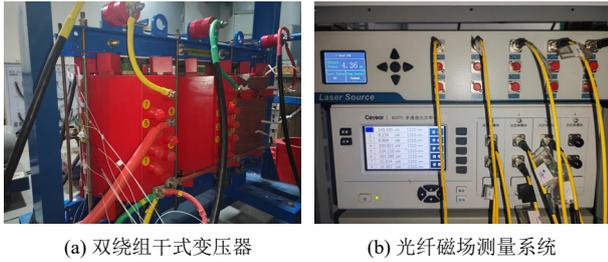


图 11 动模实验室干式变压器及光纤磁场测量系统

Fig. 11 Dynamic model laboratory dry transformer and optical fiber magnetic field measurement system

利用光纤漏磁场传感器对变压器的漏磁场信号进行测量，并对测量结果进行滤波处理，消除谐波和数据采集过程中的噪声。

图 12 为 4 号测点分别在正常情况、绕组上部局部鼓包、绕组上端轴向压缩、绕组中部匝间短路的轴向磁感应强度，其中 4 号测点距绕组上端 87.5 mm。

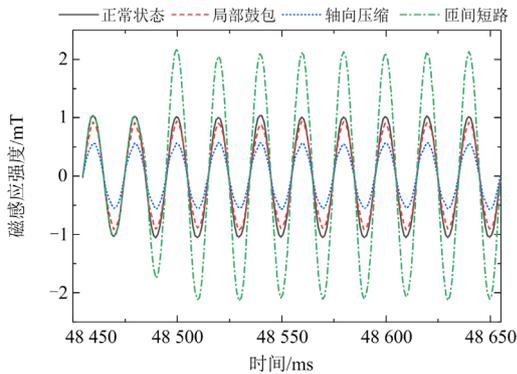


图 12 动模实验实测轴向磁感应强度

Fig. 12 Axial magnetic induction intensity measured by dynamic model experiment

当绕组发生两类绕组形变故障时，由于 4 号测点所处位置靠近绕组变形处，该测点的磁感应强度幅值均发生了改变，其中发生轴向压缩时变化更加明显。2 号测点距绕组下端 87.5 mm，当发生两类绕组形变故障时，由于该测点距离绕组变形处较远，测点磁感应强度幅值变化不大。

当绕组中部发生匝间短路时，测点测得的磁感应强度幅值明显增大，此时故障录波仪记录的电流幅值变化不明显。上述实验现象与前文仿真分析结论基本一致。

通过动模实验进行故障模拟验证，实验设置的变压器绕组状态为正常情况、绕组上部局部鼓包、绕组上端轴向压缩、绕组中部匝间短路、绕组下部匝间短路。将 50 组实测样本经故障特征提取、图像预处理后，输入 ICOA-ResNet 模型进行故障诊断，结果如图 13 所示。

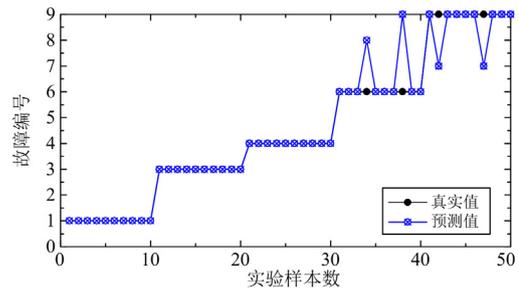


图 13 动模实验故障诊断结果

Fig. 13 Fault diagnosis results of dynamic model experiment

由图 13 可见，在进行实验变压器绕组故障诊断时，本文所提模型能够识别变压器绕组大部分故障，其准确率达到 92%。

5 结论

本文利用 ANSYS 软件建立了变压器有限元模型，对绕组变形、匝间短路故障情况下的漏磁场分布特性进行了仿真研究，并通过分析漏磁分布规律选取了 6 种故障特征类型作为诊断依据。

在进行故障诊断时，采用混沌映射策略和 Levy 飞行策略对长鼻浣熊优化算法进行改进。针对 ResNet 模型依靠经验或使用默认超参数使模型的故障分类效果相对较差的问题，利用改进长鼻浣熊优化算法对 ResNet 模型的超参数进行寻优，使 ICOA-ResNet 模型对不同数据集都能找到合适的超参数，从而提高了模型的故障分类效果。通过仿真实验分析可知，与 SVM、BPNN、CNN、ResNet50 相比，ICOA-ResNet 模型的故障诊断准确率得到有效提升。最后通过动模实验检验了所提模型诊断变压器绕组早期故障的可行性，在工程上具有一定的应用价值。

参考文献

[1] 王雪, 吴涛. 基于磁—结构直接耦合动态分析变压器绕组变形的研究[J]. 电力系统保护与控制, 2017, 45(16): 24-30.

- WANG Xue, WU Tao. Dynamic deformation analysis of transformer windings based on magnetics-structure direct coupled-field[J]. Power System Protection and Control, 2017, 45(16): 24-30.
- [2] 欧阳鑫, 李志斌. 基于样本扩充和特征优选的 IGWO 优化 SVM 的变压器故障诊断技术[J]. 电力系统保护与控制, 2023, 51(18): 11-20.
OUYANG Xin, LI Zhibin. Transformer fault diagnosis technology based on sample expansion and feature selection and SVM optimized by IGWO[J]. Power System Protection and Control, 2023, 51(18): 11-20.
- [3] DENG X, ZHANG Z, ZHU H, et al. Early fault diagnosis of transformer winding based on leakage magnetic field and DSAN learning method[J]. Frontiers in Energy Research, 2023, 10.
- [4] 邓祥力, 廖玥琳, 朱宏业, 等. 基于数字孪生模型电流动态时间规整差异度的变压器早期故障辨识[J]. 电力系统保护与控制, 2023, 51(12): 156-167.
DENG Xiangli, LIAO Yuelin, ZHU Hongye, et al. Early fault identification for a transformer based on current dynamic time warping difference of a digital twin model[J]. Power System Protection and Control, 2023, 51(12): 156-167.
- [5] 杨贤, 周丹, 王朋, 等. 基于优化 TQWT 和 LE 的变压器绕组状态检测[J]. 电力自动化设备, 2023, 43(8): 188-194.
YANG Xian, ZHOU Dan, WANG Peng, et al. Detection of transformer winding condition based on optimized TQWT and LE[J]. Electric Power Automation Equipment, 2023, 43(8): 188-194.
- [6] 赵仲勇, 唐超, 李成祥, 等. 基于频率响应二值化图像的变压器绕组变形故障诊断方法[J]. 高电压技术, 2019, 45(5): 1526-1534.
ZHAO Zhongyong, TANG Chao, LI Chengxiang, et al. Diagnosis method of transformer winding deformation faults based on frequency response binary image[J]. High Voltage Engineering, 2019, 45(5): 1526-1534.
- [7] 王艳, 李伟, 赵洪山, 等. 基于油中溶解气体分析的 DBN-SSAELM 变压器故障诊断方法[J]. 电力系统保护与控制, 2023, 51(4): 32-42.
WANG Yan, LI Wei, ZHAO Hongshan, et al. Transformer DGA fault diagnosis method based on DBN-SSAELM[J]. Power System Protection and Control, 2023, 51(4): 32-42.
- [8] 周院超, 王雪. 基于磁场测量的变压器绕组形变在线监测方法[J]. 电测与仪表, 2017, 54(17): 58-63, 87.
ZHOU Yuanchao, WANG Xue. The online monitoring method of transformer winding deformation based on magnetic field measurement[J]. Electrical Measurement & Instrumentation, 2017, 54(17): 58-63, 87.
- [9] SHANG H, ZHOU Q, OUYANG X, et al. Simulation analysis for partial deformation of transformer winding and distortion of magnetic leakage distribution considering asymmetric mechanical constraint[C]// 22nd International Symposium on High Voltage Engineering (ISH 2021), Hybrid Conference, 2021, Xi'an, China: 1083-1088.
- [10] 郑玉平, 龚心怡, 潘书燕, 等. 变压器匝间短路故障工况下的漏磁特性分析[J]. 电力系统自动化, 2022, 46(15): 121-127.
ZHENG Yuping, GONG Xinyi, PAN Shuyan, et al. Analysis on leakage flux characteristics of turn-to-turn short-circuit fault for power transformer[J]. Automation of Electric Power Systems, 2022, 46(15): 121-127.
- [11] 周晓华, 冯雨辰, 陈磊, 等. 改进秃鹰搜索算法优化 SVM 的变压器故障诊断研究[J]. 电力系统保护与控制, 2023, 51(8): 118-126.
ZHOU Xiaohua, FENG Yuchen, CHEN Lei, et al. Transformer fault diagnosis based on SVM optimized by the improved bald eagle search algorithm[J]. Power System Protection and Control, 2023, 51(8): 118-126.
- [12] 吴杰康, 覃炜梅, 梁浩浩, 等. 基于自适应极限学习机的变压器故障识别方法[J]. 电力自动化设备, 2019, 39(10): 181-186.
WU Jiekang, QIN Weimei, LIANG Haohao, et al. Transformer fault identification method based on adaptive extreme learning machine[J]. Electric Power Automation Equipment, 2019, 39(10): 181-186.
- [13] 李平, 胡根铭. 基于数据增强型一维改进卷积神经网络的变压器故障诊断方法[J]. 电网技术, 2023, 47(7): 2957-2966.
LI Ping, HU Genming. Transformer fault diagnosis method based on data enhanced one-dimensional improved convolutional neural network[J]. Power System Technology, 2023, 47(7): 2957-2966.
- [14] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA: 770-778.
- [15] 梁立锋, 刘秀娟, 张宏兵, 等. 超参数对 GRU-CNN 混合深度学习弹性阻抗反演影响研究[J]. 物探与化探, 2021, 45(1): 133-139.
LIANG Lifeng, LIU Xiujuan, ZHANG Hongbing, et al. A study of the effect of hyperparameters GRU-CNN hybrid deep learning EI inversion[J]. Geophysical and Geochemical Exploration, 2021, 45(1): 133-139.
- [16] 余维, 李阳, 钟李红, 等. 基于改进实数编码遗传算法的神经网络超参数优化[J]. 计算机应用, 2024, 44(3): 671-676.

SHE Wei, LI Yang, ZHONG Lihong, et al. Hyperparameter optimization for neural network based on improved real coding genetic algorithm[J]. Journal of Computer Applications, 2024, 44(3): 671-676.

[17] DEHGHANI M, MONTAZERI Z, TROJOVSKÁ E, et al. Coati optimization algorithm: a new bio-inspired metaheuristic algorithm for solving optimization problems[J]. Knowledge-Based Systems, 2023, 259: 110011.

[18] 邓祥力, 严康, 朱宏业, 等. 基于变压器绕组电路-漏磁场多状态解析模型的早期故障保护[J]. 电网技术, 2023, 47(9): 3808-3821.

DENG Xiangli, YAN Kang, ZHU Hongye, et al. Transformer winding early fault protection based on circuit-magnetic leakage field multi-state analytical model[J]. Power System Technology, 2023, 47(9): 3808-3821.

[19] 梁振光, 唐任远. 大型变压器三维瞬态涡流场场路耦合模型[J]. 电工技术学报, 2003, 18(5): 17-22.

LIANG Zhenguang, TANG Renyuan. Coupled field-circuit model of 3D transient eddy current field for large transformers[J]. Transactions of China Electrotechnical Society, 2003, 18(5): 17-22.

[20] 咸日常, 张冰倩, 刘兴华, 等. 应用有限元分析电力变压器绕组匝间短路的暂态特征[J]. 电机与控制学报, 2021, 25(10): 130-138.

XIAN Richang, ZHANG Bingqian, LIU Xinghua, et al. Application of finite element analysis to transient characteristics of interturn short circuit in power transformer windings[J]. Electric Machines and Control, 2021, 25(10): 130-138.

[21] 邓祥力, 朱宏业, 严康, 等. 基于光纤漏磁场测量的变压器磁平衡保护研究[J/OL]. 电工技术学报: 1-15[2023-07-09]. DOI:10.19595/j.cnki.1000-6753.tces.2003.05.004.

DENG Xiangli, ZHU Hongye, YAN Kang, et al. Research on magnetic balance protection of transformers based on optical fiber leakage magnetic field measurement[J/OL]. Transactions of China Electrotechnical Society: 1-15[2023-07-09]. DOI: 10.19595/j.cnki.1000-6753.tces.2003.05.004.

[22] 王明方, 王志刚, 谭梓荣, 等. 基于自适应多特征融合算法的变压器绕组故障诊断方法[J]. 变压器, 2021, 58(7): 42-46.

WANG Mingfang, WANG Zhigang, TAN Zirong, et al. Fault diagnosis method of transformer winding based on adaptive multi-feature fusion algorithm[J]. Transformer, 2021, 58(7): 42-46.

[23] TANG W H, SHINTEMIROV A, WU Q H. Detection of minor winding deformation fault in high frequency range for power transformer[C]// IEEE PES General Meeting, Minneapolis, July 25-29, 2010, MN, USA: 1-6.

[24] YOUSOF M F M, EKANAYAKE C, SAHA T K. Frequency response analysis to investigate deformation of transformer winding[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2015, 22(4): 2359-2367.

[25] 周院超. 基于漏磁场检测的变压器绕组变形在线监测方法研究[D]. 北京: 华北电力大学, 2017.

ZHOU Yuanchao. Research on method of on-line monitoring of transformer winding deformation based on magnetic field measurement[D]. Beijing: North China Electric Power University, 2017.

[26] 刘建锋, 刘梦琪, 董倩雯, 等. 基于改进 VMD 去噪和优化 ELM 方法的变压器早期故障诊断[J]. 电力科学与技术报, 2023, 38(6): 55-66.

LIU Jianfeng, LIU Mengqi, DONG Qianwen, et al. Transformer early fault diagnosis based on improved VMD denoising and optimized ELM method[J]. Journal of Electric Power Science and Technology, 2023, 38(6): 55-66.

[27] 鲁英达, 张菁. 基于改进猎人猎物算法的 VMD-KELM 短期负荷预测[J]. 电气工程学报, 2023, 18(4): 228-238.

LU Yingda, ZHANG Jing. VMD-KELM short-term load forecasting based on improved hunter prey algorithm[J]. Journal of Electrical Engineering, 2023, 18(4): 228-238.

[28] 邓帅. 基于改进贝叶斯优化算法的 CNN 超参数优化方法[J]. 计算机应用研究, 2019, 36(7): 1984-1987.

DENG Shuai. Hyper-parameter optimization of CNN based on improved Bayesian optimization algorithm[J]. Application Research of Computers, 2019, 36(7): 1984-1987.

收稿日期: 2023-09-28; 修回日期: 2024-03-08

作者简介:

刘建锋(1968—), 男, 博士, 副教授, 从事电力设备在线监测、数字化变电站智能设备等研究; E-mail: bansen@sina.com

李志远(1996—), 男, 硕士研究生, 从事变压器绕组故障诊断研究。E-mail: 736634592@qq.com

(编辑 许威)