

DOI:10.19651/j.cnki.emt.2107602

# 基于改进粒子群算法与油中溶解气体的 变压器故障诊断的研究\*

肖云波 范 菁 张 宜 乔钰彬

(云南民族大学 电气信息工程学院 云南省高校信息与通信安全灾备重点实验室 昆明 650000)

**摘要:** 利用电力变压器故障时产生的气体(DGA)来对变压器进行故障诊断已经成为国内外重要的诊断方法。本文选择采用卷积神经网络(CNN)作为变压器故障的诊断模型,对电力变压器进行故障诊断。但CNN的诊断性能很大程度上取决于它的结构,存在着模型超参数难以人工选择的问题。针对该问题,为了提高模型的诊断准确率,设计了利用改进粒子群算法(IPSO)来对CNN的超参数进行自动寻优。通过对PSO算法中的惯性权重 $w$ 以及学习因子 $c_1$ 、 $c_2$ 进行改进,提高粒子的寻优能力,从而构建出性能更好的诊断模型,达到提高诊断准确率的目的。实验结果表明,IPSO算法具有比PSO更好的全局寻优能力和局部寻优能力,且基于IPSO算法搭建的CNN比人工经验搭建的CNN具有更高的诊断准确率,准确率提高了5.84%。

**关键词:** 卷积神经网络;变压器诊断;DGA;改进粒子群算法

中图分类号: MT41 文献标识码: A 国家标准学科分类代码: 470.40

## Research on transformer fault diagnosis based on improved particle swarm algorithm and dissolved gas in oil

Xiao Yunbo Fan Jing Zhang Yi Qiao Yubin

(University Key Laboratory of Information and Communication on Security Backup and Recovery in Yunnan Province, School of Electrical and Information Technology, Yunnan Minzu University, Kunming 650000, China)

**Abstract:** Using the gas (DGA) generated when a power transformer fails to diagnose the transformer fault has become an important diagnostic method at home and abroad. This paper chooses to use convolutional neural network (CNN) as the transformer fault diagnosis model to diagnose the power transformer. However, the diagnostic performance of CNN largely depends on its structure, and there is a problem that it is difficult to manually select model hyperparameters. Aiming at this problem, in order to improve the diagnostic accuracy of the model, an improved particle swarm optimization algorithm (IPSO) is designed to automatically optimize the hyperparameters of CNN. By improving the inertia weight  $w$  and the learning factors  $c_1$  and  $c_2$  in the PSO algorithm, the optimization ability of the particles is improved, thereby constructing a diagnostic model with better performance and achieving the purpose of improving the accuracy of the diagnosis. The experimental results show that the IPSO algorithm has better global and local optimization capabilities than PSO, and the CNN built based on the IPSO algorithm has a higher diagnostic accuracy than the CNN built by human experience, and the accuracy rate is increased by 5.84%.

**Keywords:** convolutional neural network; transformer diagnosis; DGA; improved particle swarm algorithm

## 0 引 言

电力变压器作为变电环节的重要设备,虽然在我们身边不经常接触,但却对我们的生活产生了巨大的作用。在国内电力系统中还在使用的电力变压器中,有很大一部分

已经具备了长时间的使用年限,存在着绝缘材料劣化等安全隐患<sup>[1]</sup>,这些电力变压器一旦出现事故将会造成严重的影响,因此对电力变压器的故障情况做出精准的诊断具有非常重要的意义。

利用变压器故障时产生的气体(DGA)对变压器进行

收稿日期:2021-08-16

\* 基金项目:国家自然科学基金项目(61540063)、云南省应用基础研究计划项目(2018FD055)资助

故障诊断在国内外已经成为了重要的手段。由于现代智能技术的快速发展,基于智能的诊断方法也逐渐取代了传统的方法。其中智能诊断的方法主要包括模糊理论、专家系统、神经网络<sup>[2-3]</sup>、支持向量机(SVM)等,现有的这些智能诊断方法提高了变压器故障诊断准确率<sup>[4]</sup>。专家系统的方法具有可解释性强、不需要太多数据的特点,文献[5]提出构建基于故障树的变压器故障诊断专家系统,提高了故障查找的准确率。SVM方法具有分类思想简单、操作易于实现的特点,文献[6]提出采用烟花算法优化 SVM 模型,从而提高了变压器故障诊断的准确率,但 SVM 对于多分类问题的效果还有待提高。神经网络的方法具有学习能力强、对信息特征能进行深度挖掘的特点,常用于多分类问题。文献[7]提出一种基于 CNN 的变压器故障诊断方法,并与 SVM、ANN 等其他方法进行了对比,经过实验对比 CNN 的诊断准确率是其中最高的。但 CNN 模型也存在超参数难以人工选择的问题,选择合适的参数对 CNN 的诊断性能有着较大影响。

由于 CNN 本身具有强大的特征提取能力,能够深度挖掘数据的特征信息<sup>[8-9]</sup>。因此本文选择采用 CNN 作为电力变压器故障诊断的模型,并针对构建 CNN 模型过程中超参数(如卷积核个数及大小、激活函数的种类等)难以人工选择的问题,提出利用改进的粒子群算法对 CNN 的超参数进行自动寻优,从而构建出性能更好的模型,达到提高诊断准确率的目的。

## 1 卷积神经网络(CNN)

CNN 是深度学习的代表算法之一,主要具有两个特点,一个是局部连接,另一个是权值共享。这两个特点减少了权值的数量使得网络易于优化,降低了过拟合的风险。CNN 一般包含有输入层、输出层、卷积层、池化层、和全连接层等。在这其中卷积层和池化层又处于整个网络中比较核心的位置。

### 1.1 卷积层

卷积层的作用是通过多个卷积核对连接的上一层部分区域进行卷积,从而获得相应的特征信息。在传统神经网络中层与层之间采用全连接的方式进行连接,这将导致网络的权重参数过多,使得网络难以进行训练,且容易过拟合。而卷积层中卷积核采用权值共享的方式进行运算,能有较解决这些问题。卷积层的卷积过程如图 1 所示,输出结果如式(1)所示。

$$x_j^n = f\left(\sum_{i \in m_j} x_i^{n-1} * k_{ij}^n + b_i^n\right) \quad (1)$$

其中,  $x_j^n$  表示为第  $n$  层中的第  $j$  个特征图,  $m_j$  表示为输入特征图的集合,  $k_{ij}^n$  表示为卷积核,  $b_i^n$  表示偏置,  $f$  表示为激活函数,  $*$  为卷积运算。

### 1.2 池化层

池化层的主要作用是去除冗余信息、进行特征降维,从




图 1 卷积过程

而降低过拟合的风险。在卷积神经网络中,池化层一般结合卷积层一起使用。池化层又可分为最大池化(max pooling)和平均池化(average pooling)。最大池化就是在我们选择的每一个采样区域中,选择这个采样区域中的最大值,将其作为这个采样区域的输出,可以过滤掉部分不重要的特征;平均池化则是将每一个采样区域中的值做平均后用作这个区域的输出值。对一些不重要的特征信息,平均池化不像最大池化那样完全滤去,而是淡化,以此来强化那些重要的特征。最大池化过程如图 2 所示。




图 2 最大池化过程

## 2 粒子群算法的改进

### 2.1 标准粒子群算法(PSO)

粒子群算法(PSO)是通过设计一种特殊粒子,来模拟鸟类觅食过程的一种群智能算法,其中“食物”就代表问题的最优解<sup>[10-12]</sup>。在算法当中,每个粒子都代表一只鸟,搜索解的范围就代表寻找食物的范围,所有的粒子都具有 1 个位置向量和 1 个速度向量。每个粒子将自己历史中搜寻到效果最佳的解作为局部最优解(pb),并与其他粒子进行共享,将效果最好的 pb 作为当前的全局最优解(gb)。随着每次的迭代,粒子根据式(2)和(3)来更新当前的速度和位置,当达到终止要求时输出最优解。

粒子群的位置更新公式:

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 r_1 (pb_{id} - x_{id}^k) + c_2 r_2 (gb_d - x_{id}^k) \quad (2)$$

粒子群速度更新公式:

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (3)$$

其中,  $k$  表示粒子群的当前迭代次数,  $\omega$  表示惯性权值,  $c_1$  和  $c_2$  表示学习因子,  $v_{id}$  和  $x_{id}$  分别表示粒子  $i$  的第  $d$  维位置和速度,  $pb_{id}$  表示为粒子  $i$  的局部最优值的第  $d$  维,  $gb_d$  表示为全局最优值的第  $d$  维,  $r_1$  和  $r_2$  则表示 0~1 的随机数。

粒子群算法流程步骤如图 3 所示。

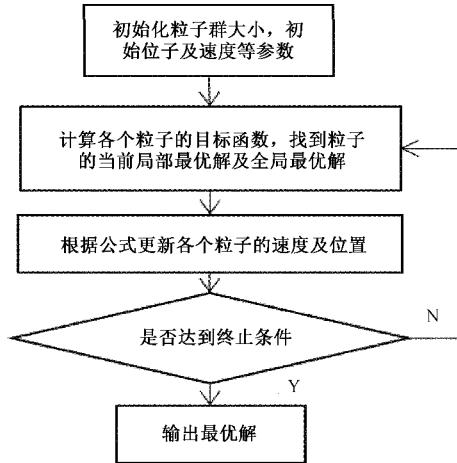


图 3 PSO 算法流程

2.2 改进粒子群算法 (IPSO)

标准粒子群算法具有寻优范围广、编码易实现等优点, 所以经常被用于各种寻求最优解的问题当中。但粒子群算法也存在容易陷入局部最优、形成早熟的问题, 对此, 专家学者对粒子群算法进行了很多深入研究。

1) 惯性权重的改进

在 PSO 算法中,  $\omega$  影响着粒子的寻优能力,  $\omega$  越小, 粒子之前的运动状态就越少影响当前的行为。当惯性权重  $\omega$  的值较大时, 使得粒子具有较大的飞行速度, 有利于粒子群的全局寻优; 当惯性权重  $\omega$  的值较小时, 使得粒子的飞行速度较小, 有利于后期粒子群的局部寻优。对此, 许多研究者选择采用惯性权值线性递减的方式, 来对算法进行改进。经研究发现, 惯性权值采用非线性递减的策略<sup>[13-14]</sup>比线性递减的策略更易于粒子的寻优。本文对惯性权重的改进采用非线性递减的方式, 如式(4)所示。

$$\omega = \omega_{\max} - (\omega_{\max} - \omega_{\min}) \left( \frac{t}{T_{\max}} \right)^2 \quad (4)$$

式中:  $\omega_{\max}$  和  $\omega_{\min}$  表示  $\omega$  的最大值和最小值;  $t$  表示当前迭代次数;  $T_{\max}$  表示最大的迭代次数;

2) 学习因子的改进

在对 PSO 算法进行改进的研究当中, 很多只考虑了惯性权值  $\omega$  对粒子寻优的影响, 而忽略了学习因子  $c_1, c_2$  的作用<sup>[15]</sup>。在 PSO 中,  $c_1, c_2$  同样对算法的寻优能力有着重要影响, 当  $c_1$  较大  $c_2$  较小时, PSO 在初期具有更好的全局寻优能力; 而当  $c_2$  较大  $c_1$  较小时, PSO 在后期具有更好的局部寻优能力; 因此对学习因子的改进采用非线性变化的方式, 如式(5)所示。

$$\begin{cases} c_1 = 1.3 + 1.2 \cos\left(\frac{\pi \cdot t}{T_{\max}}\right) \\ c_2 = 2 - 1.2 \cos\left(\frac{\pi \cdot t}{T_{\max}}\right) \end{cases} \quad (5)$$

式中:  $t$  表示当前迭代次数,  $T_{\max}$  表示最大的迭代次数, 学习因子随着迭代次数的增加非线性变化。

3 变压器故障诊断方法

3.1 输入输出的选择

变压器在运行过程中会产生许多与运行状态密切相关的数 据, 在这当中油中溶解气体 (DGA) 又是最常用的。当油浸式变压器发生故障时, 会产生大量含碳、氢、氧元素的气体溶解在变压器油中。其中氢气 ( $H_2$ )、甲烷 ( $CH_4$ )、乙烷 ( $C_2H_6$ )、乙烯 ( $C_2H_4$ )、乙炔 ( $C_2H_2$ ) 又是该过程中最主要产生的气体, 因此本文选择将这 5 种气体的含量作为输入数据的其中 5 个纬度。而模型的输出就对应着电力变压器的各种故障类型。

为了使故障诊断结果更加精准, 输入数据需要更高维度的特征, 将所生成 5 种气体的总含量以及这 5 种气体各自占总气体含量的比例, 作为输入数据的特征。由此便得到以  $C(H_2), C(CH_4), C(C_2H_6), C(C_2H_4), C(C_2H_2), C, C(H_2)/C, C(CH_4)/C, C(C_2H_6)/C, C(C_2H_4)/C, C(C_2H_2)/C$  为特征的输入数据, 其中  $C(H_2), C(CH_4), C(C_2H_6), C(C_2H_4), C(C_2H_2)$  分别表示 5 种气体的含量,  $C$  表示 5 种气体的总体含量。

3.2 数据预处理

变压器发生故障时, 其故障类型主要可分为包含正常状态在内的 7 种状态, 对不同故障类型进行编码, 如表 1 所示。

表 1 故障编码

故障类型	故障编码
低温过热	0000001
中温过热	0000010
高温过热	0000100
局部放电	0001000
低能放电	0010000
高能放电	0100000
正常状态	1000000

选取这 7 种故障类型对应的故障编码作为诊断模型的输出。

对于 CNN 模型来说, 用于训练的数据质量对训练的效果有着很大的影响。我们用于训练的数据源于变压器故障时所产生的油中溶解气体含量, 而在采集、储存、收集这些数据的时难免会碰到各种干扰, 使得部分数据不能真实地反映变压器的状态。这将会很大程度的影响模型训练的结果。因此本文选择利用聚类的方式, 基于距离判据, 剔除所获数据集中可能存在的噪声数据。

首先利用 Canopy 加 K-means 聚类的方式<sup>[16-17]</sup>将 DGA 数据集聚类成  $N$  个类, 计算出每个类的类内平均距离  $d_{av}$ , 最后将每个类中任意数据  $x$  与其对应类别的聚类中心  $d_i$

进行距离判定,若  $d_i > d_{min} \cdot K_c$ , 则判定该数据为噪声数据,其中  $K_c$  为设置的离群倍率。Canopy 聚类过程及 K-means 聚类过程分别如图 4 和 5 所示。

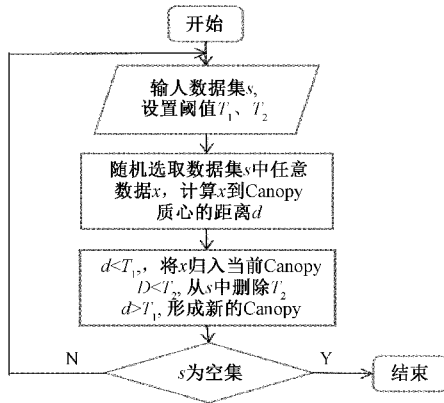


图4 Canopy 聚类过程

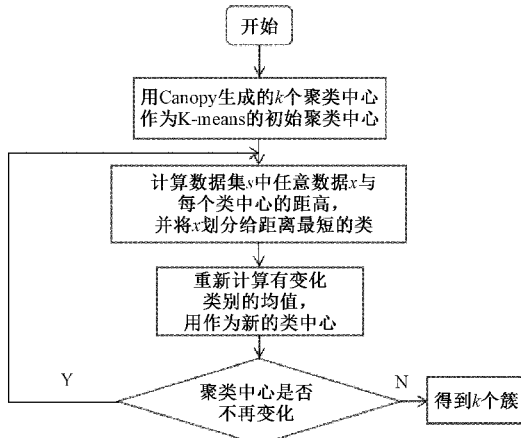


图5 K-means 聚类过程

在剔除噪声数据之后,为保持原有各类数据样本的数量,利用 SMOTE 数据增广的方式对每个类生成相应被剔除个数的数据。最终得到与原数据集各变压器故障类别数

量相等的 DGA 数据,在剔除了潜在噪声数据的同时,又保持了样本数量不变性。

### 3.3 基于改进粒子群算法的 CNN 搭建

由于输入数据为结构较为简单的  $11 \times 1$  维的气体数据,盲目增加卷积层和池化层会增大网络复杂度和网络学习时间,且不能有效提高诊断效率。因此,本文所搭建的卷积神经网络的结构包含 1 个输入层、2 个卷积层(C1、C2)、2 个池化层(P1、P2)、1 个全连接层和 1 个输出层。

由于 CNN 模型中超参数众多,凭借经验的人工选择的方法是非常困难的,往往因为部分参数选择的不利,从而导致整个模型训练的效果不理想。在之前的实验中,仅仅因为激活函数的差异,CNN 模型的准确率就相差了 5% 左右。因此利用文中提出的改进粒子群算法(IPSO)对 CNN 超参数进行寻优,得出效果最优的参数配置。改进粒子群算法优化 CNN 的步骤流程如图 6 所示。

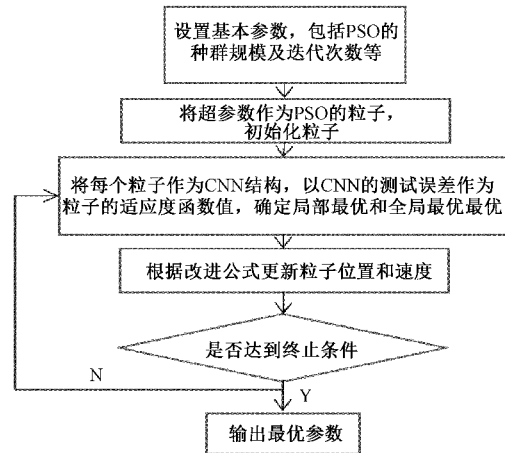


图6 IPSO 优化 CNN 过程

最终输出的参数就是寻优后的 CNN 最佳超参数。为了使构建的 CNN 模型性能优异,需要寻优的超参数范围应该设置较广,表 2 所示为 CNN 各超参数寻优范围。所要寻优的超参数有 16 个,对应着表 2 中的 16 个粒子。

表2 CNN 寻优超参数及范围

对应粒子	超参数	寻优范围
X0	C1 层卷积核个数	2~32
X1	C2 层卷积核个数	2~32
X2	C1 层卷积核大小	$2 \times 1, 3 \times 1, 4 \times 1, 5 \times 1$
X3	C2 层卷积核大小	$2 \times 1, 3 \times 1, 4 \times 1, 5 \times 1$
X4	P1 层采样区域大小	$2 \times 1, 3 \times 1, 4 \times 1$
X5	P2 层采样区域大小	$2 \times 1, 3 \times 1, 4 \times 1$
X6	P1 层步长	1~3
X7	P2 层步长	1~3
X8	全连接层神经元个数	32~256
X9	训练批次大小	5~50
X10	训练损失函数	categorical_crossentropy, binary_crossentropy, squared_hinge
X11	Dropout 大小	0.1, 0.2, 0.3, 0.4
X12	C1 层激活函数类型	ReLU, sigmoid, Softmax, tanh
X13	C2 层激活函数类型	ReLU, sigmoid, Softmax, tanh
X14	全连接层激活函数类型	ReLU, sigmoid, Softmax, tanh
X15	输出层激活函数类型	ReLU, sigmoid, Softmax, tanh

### 4 实验验证及分析

为了验证本文所提方法对提高变压器故障诊断性能的可行性,进行实验验证。模型的搭建选择使用 Python 编程语言,基于 Anaconda 发行平台,主要使用框架 Keras。本文所使用的数据集从不同相关论文中收集而来,总共包含 390 组变压器 DGA 数据及其故障类型,故障类型与对应组数如表 3 所示。

首先将 390 组数据集进行预处理。通过聚类的方式并以距离为判据,最终筛选出 22 组离群数据并剔除,接着使用 smote 增广算法对数据集进行了补充,形成了与原数据集数量相同的 390 组数据。

表 3 数据类型分布

故障类型	组数
正常状态	64
低温过热	31
中温过热	46
高温过热	89
局部放电	48
低能放电	51
高能放电	61

然后分别用基于人工经验的方式和基于 IPSO 算法的方式搭建 CNN,其中超参数的结构如表 4 所示。

表 4 两种方式超参数对比

对应粒子	超参数	人工经验	IPSO
X0	C1 层卷积核个数	8	17
X1	C2 层卷积核个数	16	28
X2	C1 层卷积核大小	3×1	3×1
X3	C2 层卷积核大小	3×1	4×1
X4	P1 层采样区域大小	2×1	2×1
X5	P2 层采样区域大小	2×1	3×1
X6	P1 层步长	1	1
X7	P2 层步长	1	2
X8	全连接层神经元个数	128	256
X9	训练批次大小	30	35
X10	训练损失函数	categorical_crossentropy	binary_crossentropy
X11	Dropout 大小	0.2	0.3
X12	C1 层激活函数类型	ReLU	ReLU
X13	C2 层激活函数类型	ReLU	ReLU
X14	全连接层激活函数类型	ReLU	sigmoid
X15	输出层激活函数类型	Softmax	Softmax

最后,将预处理过的数据集按 4 : 1 的比例随机划分成训练集(312 组)和测试集(78 组),迭代次数设置为 500 次,带入到 CNN 中进行训练和测试。通过作图来分析基于两种方法的 CNN 准确率和误差随迭代次数的变化。其中基于人工经验和基于 IPSO 算法的卷积神经网络的准确率-误差图分别如图 7 和 8 所示。

从图中可以看出来,两种方式的误差曲线下落的都十分迅速,并且准确率曲线都平滑的上升,说明模型正在进行有效的学习。其中两图中的训练准确率曲线与测试准确率曲线在整个迭代过程中,都没有大的间隔,几乎快重合,说明两个模型均没有出现拟合的情况。但是基于 IPSO 寻优的 CNN 具有更优的诊断性能,迭代次数到 100 次时两种误差均已下降到 0.1 以下。经过 500 迭代之后,基于 IPSO 算法的 CNN 相比人工经验搭建的 CNN,具有更高的诊断准确率和更低的误差,诊断精度大幅提高。分




图 7 准确率-误差(人工)

别对两种方式的 10 次诊断结果求平均,两种方式的变压器故障诊断结果如表 5 所示。

为了能更直观看出随迭代次数非线性变化的  $\omega, c_1, c_2$  对算法的影响,通过作 IPSO-CNN 及 PSO-CNN 的测试试






图 8 准确率-误差 (IPSO)

表 5 诊断结果

诊断方式	CNN	IPSO-CNN
训练准确率	0.931 8	0.990 4
训练误差	0.157 1	0.018 7
测试准确率	0.925 3	0.983 7
测试误差	0.646 5	0.038 3

差-迭代次数(loss-epochs)可视图,分析 IPSO 算法性能。设置粒子迭代次数为 50 次,粒子个数为 15。

图 9 所示为标准 PSO 优化 CNN 迭代图,其中  $\omega = 0.5$ ,  $c_1 = c_2 = 2$ , 纵坐标 loss 为 CNN 的测试误差,横坐标 epoches 为粒子迭代次数。由图可见在 PSO 粒子寻优前期 loss 下降趋于缓慢,全局寻优能力较弱,容易导致陷入局部最优,影响算法整体效果,直到迭代后期还未收敛到最优位置,最终 loss=0.186 7。




图 9 PSO-CNN

图 10 所示为 IPSO 优化 CNN 迭代图,由图可知在

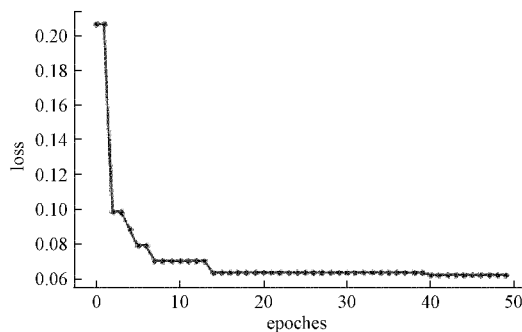


图 10 IPSO-CNN

IPSO 粒子寻优前期,粒子的全局寻优的能力更好,loss 下降的很迅速,当 epoches=14 时,loss 趋于收敛;在寻优后期 epoches=40 时,loss 出现轻微下降,粒子还具有良好的局部寻优的能力,最终 loss=0.062 1。

## 5 结 论

本文通过利用 CNN 及 DGA 气体数据来对电力变压器进行故障检测,并针对 CNN 超参数人工选择困难的问题,选择用改进粒子群算法对超参数进行寻优,从而构建出诊断性能更好的诊断模型。通过对 PSO 中惯性权值和学习因子采用非线性动态变化的方式进行改进,形成 IPSO 算法。首先在数据预处理阶段,先对潜在的噪声数据进行了剔除,提高了实验可靠性。然后通过实验分析可知,在前期寻优过程中 IPSO 比 PSO 具有更强的全局寻优能力,收敛速度更快,不易陷入局部最优,并且在寻优后期还具有良好的局部寻优能力;基于 IPSO 算法搭建的 CNN 相比基于人工经验搭建的 CNN 具有更高的准确率和更低的测试误差,模型准确率提高了 5.84%。这充分说明了本文提出方法的可行性。针对变压器故障下一步的研究,还可以进一步完善,例如在不影响诊断准确率的前提下缩短诊断时间以及将更多超参数考虑在内。

## 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] 夏飞,罗志疆,张浩,等.混合神经网络在变压器故障诊断中的应用[J].电子测量与仪器学报,2017,31(1):118-124.
- [3] 张奎,王建南,王肖峰.基于神经网络的变压器故障诊断[J].电子测量技术,2017,40(12):98-101.
- [4] 石鑫.基于深度学习的变压器故障诊断技术研究[D].保定:华北电力大学,2016.
- [5] 熊铠.基于故障树的电力变压器故障分析[J].机电信息,2019(30):25,28.
- [6] 张邵杰.基于烟花算法优化 SVM 的变压器故障诊断[J].机电信息,2021(22):30-31.
- [7] 夏洪刚,郭红兵,肖金超.基于 CNN 的电力变压器故障诊断方法[J].电子设计工程,2020,28(13):189-193.
- [8] 贾京龙,余涛,吴子杰,等.基于卷积神经网络的变压器故障诊断方法[J].电测与仪表,2017,54(13):62-67.
- [9] 裴小邓,罗林,陈帅,等.面向电力变压器油中溶解气体的卷积神经网络诊断方法[J].辽宁石油化工大学学报,2020,40(5):79-85.
- [10] YANG W L, ZHOU X T, LUO Y L. Simultaneously optimizing inertia weight and acceleration coefficients via introducing new functions into PSO algorithm[J]. Journal of Physics: Conference Series, 2021, DOI:

- 10.1088/1742-6596/1754/1/012195.
- [11] ZOU D X, LI S, LI Z Y, et al. A new global particle swarm optimization for the economic emission dispatch with or without transmission losses [J]. Energy Conversion and Management, 2017, DOI: 10.1016/j.enconman.2017.02.035.
- [12] LATCHOUMI T P, BALAMURUGAN K, DINESH K, et al. Particle swarm optimization approach for waterjet cavitation peening [J]. Measurement, 2019, DOI:10.1016/j.measurement.2019.04.040.
- [13] 孟荣,赵冀宁,周通. 基于改进惯性权重粒子群算法的抢修小组快速调配策略[J]. 电网与清洁能源, 2021, 37(7):17-24.
- [14] 郭丽丽,刘勇,王卫西. 粒子群优化算法之惯性权值递减策略的改进[J]. 黑龙江大学学报, 2019, 10(1): 67-71.
- [15] 张春韵,邹德旋,沈鑫. 改进的粒子群算法在电力经济调度中的应用[J]. 制造业自动化, 2021, 43(1): 53-57, 64.
- [16] 郭朝有,许喆,马砚堃,等. 面向不平衡数据集融合 Canopy 和 K-means 的 SMOTE 改进算法[J]. 科学与技术工程, 2020, 20(22):9069-9074.
- [17] 张琳,牟向伟. 基于 Canopy+K-means 的中文文本聚类算法[J]. 图书馆论坛, 2018, 38(6):113-119.

### 作者简介

肖云波, 硕士研究生, 主要研究方向为变压器的故障诊断。

E-mail:1617657695@qq.com

范菁(通信作者), 教授, 硕士生导师, 主要研究方向为智能计算及物联网。

E-mail:Fanjing9476@ymu.edu.cn

张宜, 硕士研究生, 主要研究方向为电力系统扰动识别。

E-mail:sxlfzhangyi@qq.com

乔钰彬, 硕士研究生, 主要研究方向为变压器故障检测、深度学习。

E-mail:qybadam0616@163.com