

# 基于残差BP神经网络的变压器故障诊断

赵文清, 严海, 周震东, 邵绪强

(华北电力大学 控制与计算机工程学院, 河北 保定 071003)

**摘要:**基于传统BP神经网络的变压器故障诊断方法,当网络模型达到一定的深度时,模型的诊断性能会趋向于饱和,无法进一步提升网络模型的诊断性能,此时加深网络模型的深度反而会导致模型的诊断性能有所下降。此外,在小样本数据下,传统BP神经网络仍无法取得较好的诊断准确率。因此,为了提高变压器故障诊断准确率以及在小样本数据下的诊断性能,提出了基于残差BP神经网络的变压器故障诊断方法。所提方法采用堆叠多个残差网络模块的方式加深BP神经网络的深度,将传统BP神经网络的恒等映射学习转化为残差BP神经网络中的残差学习。同时,在每个残差网络模块中,模块的输入信息可以在模块内跨层传输,使得每个模块的输入信息可以更好地向深层网络传递,从而在小样本数据下仍可以训练得到较好的诊断模型。实验结果表明,相较于传统深层BP神经网络和传统浅层BP神经网络,所提方法具有更高的诊断准确率,同时在小样本数据下也体现出较好的诊断性能。

**关键词:**电力变压器;故障诊断;残差BP神经网络;恒等映射;残差网络模块

**中图分类号:**TM 41

**文献标志码:**A

**DOI:**10.16081/j.epae.201912021

## 0 引言

电力变压器是电力系统中的重要设施,当前我国已有较多变压器的周转时间超过一定的年限,设备不可避免地出现老化从而引起故障隐患<sup>[1]</sup>。因此,必须对变压器进行故障诊断研究,从而降低故障发生的概率。

大量实测研究表明,变压器油中溶解气体分析(DGA)技术<sup>[2-4]</sup>是作为诊断和检测变压器内部绝缘潜伏性故障的有效方法。并且在此基础上形成了三比值法<sup>[5]</sup>、Rogers<sup>[6]</sup>法等进行变压器故障诊断,这些方法的共同特征是对油中溶解气体的成分含量比值进行编码,然后由相应的编码进行对应的故障诊断。虽然这些方法具有原理简单、计算量小的优点,但是在实际的应用中,传统的IEC三比值法和相关改进三比值法<sup>[7]</sup>具有编码不全、编码边界过于绝对等缺点。因此,文献[8]基于模糊聚类,采用完全二叉树逐层划分的方式并与支持向量机相结合对变压器故障进行诊断。文献[9-10]通过优化支持向量机的核函数以降低参数选择难度的方式,对变压器的故障类型进行诊断。文献[11]在BP神经网络中引入模糊聚类及LM(Levenberg-Marquart)算法用以诊断变压器故障类型。文献[12]构建了分类深度自编码网络模型对变压器的故障进行诊断。文献[13]基于油中溶解气体,在深度信念网络中采用ReLU激活函数对变压器故障进行诊断。文献[14]提出一种

支持向量机和遗传算法相结合的方法,建立20种不同的初始输入特征集合对变压器故障进行诊断。文献[15]基于故障特征气体间的关联特征对变压器的故障进行诊断。文献[16]采用粗糙集的一对一多类支持向量机诊断变压器的故障类型。虽然上述文献中的诊断方法在诊断变压器故障时取得了一定的效果,但整体的诊断准确率仍不足。同时,上述基于传统BP神经网络的诊断方法仍存在浅层模型诊断准确率较低以及小样本数据下诊断准确率较差的问题。

针对上述问题,本文提出了基于残差BP神经网络的变压器故障诊断方法。通过堆叠多个残差网络模块的方式加深网络的层数,每个残差网络模块由2层BP神经网络组成,残差网络模块的输出为模块内第2层网络的输出加上残差模块内第1层网络的输入,将传统BP神经网络中的恒等映射学习转化为残差学习。同时,每个残差网络模块的输入信息可以在模块中跨越一层网络传递,进而使得网络可以更好地提取变压器故障数据的特征信息。因此,在小样本数据下,基于残差BP神经网络的模型仍具有较好的诊断性能。

## 1 残差BP神经网络的模型构建

### 1.1 残差网络模块

相较于传统的BP神经网络,残差BP神经网络将传统BP神经网络中的学习恒等映射函数转换为残差函数的学习。图1为传统深层BP神经网络模型结构,网络中的Layer 1—4和Layer 11—14的神经元个数为256,Layer 5—10的神经元的个数为512。由图1可以看出,网络逐层提取输入数据 $x$ 的

收稿日期:2019-03-27;修回日期:2019-10-28

基金项目:国家自然科学基金资助项目(61502168)

Project supported by the National Natural Science Foundation of China(61502168)

特征信息,同时进行逐层。

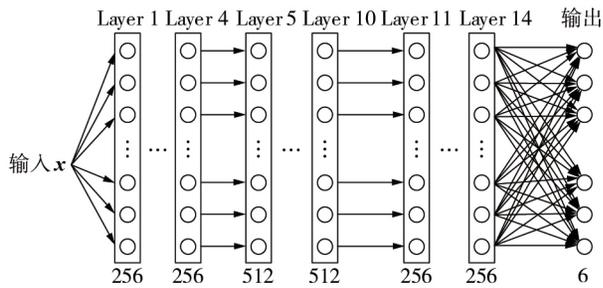


图1 传统深层BP神经网络模型

Fig.1 Model of traditional deep BP neural network

传统BP网络的连接方式如图2所示。由图可知,传统BP神经网络通过堆叠多层神经元的方式对输入数据 $x$ 进行处理。首先输入数据 $x$ 在经过多次加权、偏置、激活函数的组合操作后会产生输出 $Y_1$ ;然后计算输出 $Y_1$ 与数据标签 $Y$ 之间的误差,采用随机梯度下降法训练更新BP神经网络中各层的权重;最后在训练结束后使得传统BP神经网络的输出 $Y_1$ 尽可能地逼近数据标签 $Y$ ,从而达到恒等映射学习的目的。然而,在这种恒等映射学习的方式下,当增加网络深度时,会使得神经网络训练过程中出现梯度消失的问题,同时使整体的训练损失增大。此外,当增加传统BP神经网络模型的层数时,模型复杂度提升对数据处理的准确率应高于浅层模型。然而,在传统BP神经网络恒等映射学习的方式下,深层网络模型的测试准确率低于层数较少的网络模型。

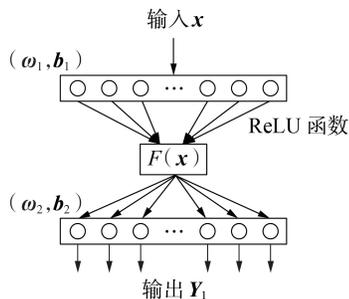


图2 传统BP神经网络的连接方式

Fig.2 Connection mode of traditional BP neural network

图3为本文所提残差BP神经网络中的残差网络模块,在单个残差网络模块中,对输入数据的处理共分为3个步骤。其中,假设数据 $x$ 对应的标签为 $H(x)$ 。

步骤1:残差模块首先将输入数据 $x$ 输入第1层网络中,经过加权、偏置和激活函数操作后输出 $F(x)$ ,如式(1)所示。

$$F(x) = R(x\omega_1 + b_1) \quad (1)$$

其中, $\omega_1$ 为第1层网络的权重; $b_1$ 为第1层网络的偏置; $R(\cdot)$ 为ReLU激活函数。

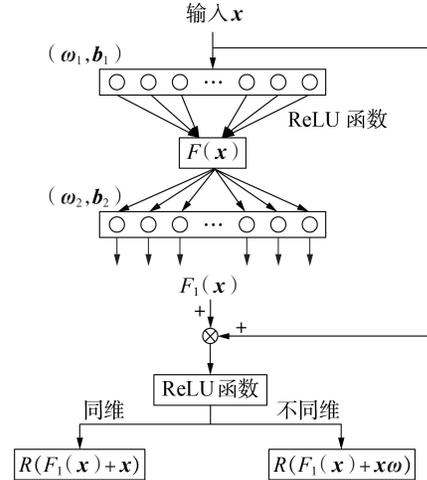


图3 残差BP神经网络的模块

Fig.3 Module of residual BP neural network

步骤2:将 $F(x)$ 输入第2层网络中经过加权和偏置操作后输出 $F_1(x)$ ,如式(2)所示。

$$F_1(x) = F(x)\omega_2 + b_2 \quad (2)$$

其中, $\omega_2$ 为第2层网络的权重; $b_2$ 为第2层网络的偏置。

步骤3:将 $F_1(x) + x$ 输入激活函数ReLU中,输出 $F_2(x)$ 如式(3)所示。

$$F_2(x) = R(F_1(x) + x) \quad (3)$$

其中, $F_2(x)$ 为当前残差网络模块的输出。 $F_1(x)$ 与 $x$ 必须具有相同的维度才能进行逐元素相加操作。当 $F_1(x)$ 与 $x$ 的维度不同时,可以将式(3)转化为式(4),通过将 $x$ 乘以权重 $\omega$ ,从而将 $x$ 转化为与 $F_1(x)$ 有相同维度的变量。

$$F_2(x) = R(F_1(x) + x\omega) \quad (4)$$

因此,残差网络可以将传统BP神经网络中的恒等映射学习转化为残差模块中的 $F_2(x)$ 逼近 $H(x)$ 的学习,进而将学习转化为学习残差 $F_1(x)$ 。同时,在每个残差网络模块中,将模块的输入跨越一层网络连接后输出到下一个残差模块中,进而使信息可以更好地在网络间进行传输。

## 1.2 残差BP神经网络模型

传统BP神经网络不仅可以实现复杂的非线性映射功能,同时网络具有一定的自适应和自学习能力。但是传统BP神经网络在网络层数达到一定的数量时,网络的性能会发生饱和,若继续增加网络深度,则会使网络的性能退化。因此,本文通过堆叠多个残差BP神经网络模块的方式,训练深层的BP神经网络,不仅避免了网络性能的退化现象,而且相较于浅层网络模型,本文所提残差BP神经网络模型具有更好的诊断性能。图4为本文所提残差BP神经网络模型结构,该模型结构与图2中的传统BP神经网络模型结构相对应。

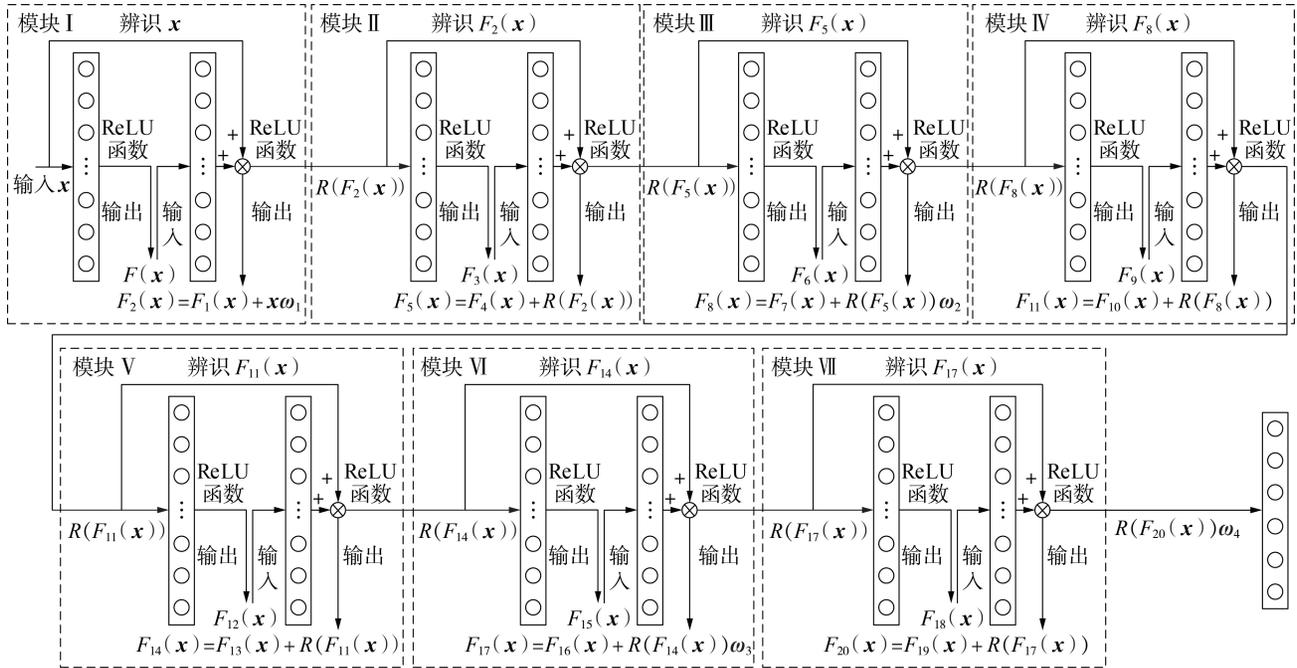


图4 残差BP神经网络模型

Fig.4 Model of residual BP neural network

本文共堆叠了7个残差BP神经网络模块(I—VII),每个残差网络模块中均堆叠了2层神经元。其中,在I、II、VI、VII这4个残差网络模块中,每层神经元的个数均为256,在III—V这3个残差网络模块中,每层神经元的个数均为512。

在残差网络模块I中, $x$ 为其输入。将 $x$ 输入第1层网络,经过加权、偏置和激活函数操作后输出 $F(x)$ ;  $F(x)$ 作为第2层网络的输入,经过加权和偏置操作后输出 $F_1(x)$ 。由于输入 $x$ 与 $F_1(x)$ 的维度不同,根据式(4)将 $x$ 乘以权重 $\omega_1$ 从而使得 $F_1(x)$ 与 $x$ 具有相同的维度。最后将 $F_2(x) = F_1(x) + x\omega_1$ 经过激活函数后得到的 $R(F_2(x))$ 作为残差网络模块I的输出。在残差网络模块II中, $R(F_2(x))$ 为其输入,经过与残差网络模块I中相同的过程后输出 $R(F_5(x))$ 作为残差网络模块III的输入。分别在残差网络模块III—VII中重复上述过程后,残差网络模块VII输出 $R(F_{20}(x))$ ,将 $R(F_{20}(x))$ 作为预测层的输入,预测 $x$ 的类别。其中,在残差网络模块I、III、VI中,每个模块的输入( $x, R(F_5(x)), R(F_{14}(x))$ )与该模块中第2层网络的输出( $F_1(x), F_7(x), F_{16}(x)$ )维度不同,因此根据式(4)将 $F_1(x), F_7(x), F_{16}(x)$ 分别乘以权重 $\omega_1, \omega_2, \omega_3$ ,使其维度与模块输入( $x, R(F_5(x)), R(F_{14}(x))$ )的维度保持一致。

## 2 基于残差BP神经网络的变压器故障诊断

本文采用DGA中 $H_2, CH_4, C_2H_6, C_2H_4, C_2H_2$ 的含量作为故障诊断的标准,将变压器的总体运行状态

分为正常( $C_1$ )、低能放电( $C_2$ )、高能放电( $C_3$ )、中低温过热( $C_4$ )、高温过热( $C_5$ )、局部放电( $C_6$ )这6种类型。由于不同变压器的气体体积分数不同,为了缩小特征气体含量值的差异,采用式(5)对特征气体含量值进行归一化处理。

$$x_{new}^i = \frac{x^i - x_{min}^i}{x_{max}^i - x_{min}^i} \quad (5)$$

其中, $i = 1, 2, \dots, 5$ 为5种特征气体的序号; $x^i$ 为训练样本中特征气体 $i$ 的原始含量值; $x_{min}^i, x_{max}^i$ 分别为训练样本中特征气体 $i$ 含量的最小值、最大值; $x_{new}^i$ 为进行归一化处理后的特征气体 $i$ 的含量值。此外,在实验时保存训练集中 $x_{min}^i, x_{max}^i$ 的值,在测试时利用该值对测试集样本进行归一化处理。

本文根据电力变压器运行过程中的故障类型将其分为6种,故障类型编码如表1所示。

表1 变压器故障类型编码

故障类型	编码	故障类型	编码
正常	1,0,0,0,0,0	中低温过热	0,0,0,1,0,0
低能放电	0,1,0,0,0,0	高温过热	0,0,0,0,1,0
高能放电	0,0,1,0,0,0	局部放电	0,0,0,0,0,1

本文采用的残差BP神经网络模型的输入数据 $x$ 为变压器的气体含量特征,特征属性维度为5。输出层的神经元个数为6,将变压器的故障类型分为6类。在残差网络模块I中,每层网络的神经元个数为256,导致残差网络模块I中第2层网络的输出 $F_1(x)$ 的特征维度为256,该特征维度与模块I中输入气体含量 $x$ 的特征维度5不匹配。因此,在残差

网络模块 I 中权重  $\omega_1$  的维度为  $5 \times 256$ , 从而使得  $F_1(x)$  的特征维度与  $x\omega_1$  的特征维度一致。在残差网络模块 III 中, 每层网络的神经元个数为 512, 第 2 层网络的输出  $F_7(x)$  的特征维度为 512。然而, 残差网络模块 III 的输入  $R(F_5(x))$  的特征维度为 256, 所以权重  $\omega_2$  的维度为  $256 \times 512$ , 从而使得  $F_7(x)$  的特征维度与  $R(F_5(x))\omega_2$  的特征维度一致。同理, 权重  $\omega_3$  的维度为  $512 \times 256$ , 从而使得  $F_{16}(x)$  的特征维度与  $R(F_{14}(x))\omega_3$  的特征维度一致。在残差网络模块 VII 中, 模块的输出为  $R(F_{20}(x))$ , 其特征维度为 256, 则权重  $\omega_4$  的维度为  $256 \times 6$ , 使得  $R(F_{20}(x))\omega_4$  的特征维度为 6, 从而实现了对变压器故障数据  $x$  的故障类别预测。

基于残差 BP 神经网络的变压器故障诊断方法在本质上是一种变压器故障分类问题。首先, 将变压器的特征气体含量数据和对应类别标签组成训练样本集和测试样本集, 利用训练样本集训练本文所提残差 BP 神经网络模型; 然后, 利用训练好的残差 BP 神经网络模型对测试样本集数据进行测试, 统计测试的准确率。

### 3 实验分析

#### 3.1 实验数据及过程

本文所采用的残差 BP 神经网络共有 7 个残差网络模块。在进行训练时, 学习率为 0.0001, 激活函数为 ReLU, 共训练 250 轮, 初始权重  $\omega$  服从均值为 0、标准差为 0.1 的高斯分布, 偏置值  $b$  的初值均为 0.01。本文使用的变压器数据集共有 560 条, 其中, 正常、低能放电、高能放电、中低温过热、高温过热、局部放电状态分别为 113、94、93、87、83、90 条。将数据集分别以 6:4、7:3、8:2 的比例建立相对应的训练集  $R_1-R_3$  和测试集  $T_1-T_3$ 。此外, 为了验证本文所提变压器故障诊断方法在小样本数据下的有效性, 在每个故障类别中等比例取变压器数据集中的 112 条数据作为训练集  $S$ , 然后在剩余数据集中等比例取 56( $S_1$ )、112( $S_2$ )、168( $S_3$ ) 条数据作为测试集。

图 5 为残差 BP 神经网络和传统深层 BP 神经网络的训练损失对比。由图 5 可以看出, 当训练轮数

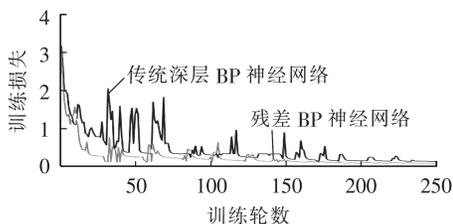


图 5 残差 BP 神经网络和传统深层 BP 神经网络的训练损失对比

Fig.5 Comparison of training loss between residual BP neural network and traditional deep BP neural network

达到 200 轮后, 二者的训练损失均趋向于稳定。同时, 在训练过程中, 残差 BP 神经网络不仅具有更好的训练稳定性, 而且整体训练损失也小于传统深层 BP 神经网络。

#### 3.2 变压器故障类型诊断性能分析

表 2 为本文所提残差 BP 神经网络模型(图 4)、传统深层 BP 神经网络模型(图 1)和传统浅层 BP 神经网络模型(与图 2 类似, 但隐含层网络为 7 层)在相对应的训练集和测试集上变压器故障数据的诊断结果。由表 2 可以看出, 残差 BP 神经网络模型在不同的测试集下均保持了较高的故障诊断准确率, 平均准确率达到 92.51%, 并且在每个测试集上的诊断效果较为稳定, 均保持在 91.52% 及以上; 传统浅层 BP 神经网络模型的诊断准确率高传统深层 BP 神经网络模型, 该结果表明加深网络深度后, 传统 BP 神经网络的诊断性能有一定程度的下降。此外, 由表 2 所示结果可知, 基于残差 BP 神经网络模型的变压器故障诊断准确率在不同测试集下均高于传统浅层 BP 神经网络和传统深层 BP 神经网络模型, 该诊断结果表明, 堆叠多个残差网络模块后, 加深 BP 神经网络的层数相较于传统 BP 神经网络不仅诊断性能没有下降, 反而有了较为明显的提升; 与传统浅层 BP 神经网络和传统深层 BP 神经网络相比, 残差 BP 神经网络模型的诊断准确率分别平均提升了 2.57% 和 5.66%。

表 2 不同模型的诊断准确率

Table 2 Diagnostic accuracy rates of different models

模型	测试集诊断准确率/%			平均诊断准确率/%
	$T_1$	$T_2$	$T_3$	
残差 BP 神经网络	91.52	92.26	93.75	92.51
传统浅层 BP 神经网络	87.94	88.69	90.18	89.94
传统深层 BP 神经网络	86.16	86.90	87.50	86.85

表 3 为在小样本数据下基于残差 BP 神经网络模型、传统深层 BP 神经网络模型和传统浅层 BP 神经网络模型的变压器故障诊断结果。由表 3 可以看出, 在小样本数据下, 虽然残差 BP 神经网络模型的诊断准确率随着测试样本集数量的增加有轻微的下降, 但是整体的平均诊断准确率仍保持在 90.38%, 相较于基于传统浅层和深层 BP 神经网络模型的变压器故障平均诊断准确率分别提高了 5.76% 和 7.15%。进而说明残差 BP 神经网络模型在小样本数

表 3 小样本数据下不同模型的诊断准确率

Table 3 Diagnostic accuracy rate of different models under small data set

模型	测试集诊断准确率/%			平均诊断准确率/%
	$S_1$	$S_2$	$S_3$	
残差 BP 神经网络	91.07	90.18	89.88	90.38
传统浅层 BP 神经网络	85.71	84.82	83.33	84.62
传统深层 BP 神经网络	83.93	83.03	82.74	83.23

据下仍具有较好的诊断性能。

图 6 为残差 BP 神经网络和传统深层 BP 神经网络对测试集  $T_1$  中变压器具体故障类型的诊断准确率。由图 6 可以看出,在 6 种故障类型诊断中,本文所提残差 BP 神经网络模型的诊断准确率均高于传统深层 BP 神经网络。

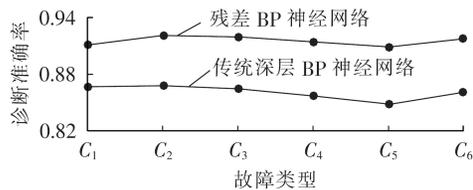


图 6 变压器故障类型的诊断结果

Fig.6 Diagnosis results of transformer fault types

在不同的故障类型诊断中,残差 BP 神经网络模型具有较强的诊断稳定性,每一故障类型的诊断准确率均保持在 90.9% 以上。表 4 为部分测试数据在训练完成的模型上的测试结果。由表可看出,对不同的故障类型数据进行测试,残差 BP 神经网络模型均准确地预测得到了相应故障数据的类型。

表 4 部分故障数据的测试结果

Table 4 Test results of partial fault data

序号	气体含量 / ( $\mu\text{L}\cdot\text{L}^{-1}$ )					实际故障类型	预测所得结果
	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>		
1	14.67	3.68	10.54	2.71	0.2	正常	C <sub>1</sub>
2	27	90	42	63	0.2	中低温过热	C <sub>4</sub>
3	73	12.3	3.33	27.1	47.9	局部放电	C <sub>6</sub>
4	135	466	70	502	9	高温过热	C <sub>5</sub>
5	119	25	12	55	84	高能放电	C <sub>3</sub>
6	80	20	6	20	62	低能放电	C <sub>2</sub>

## 4 结论

针对基于传统 BP 神经网络的变压器故障诊断方法的准确率不足以及加深传统 BP 神经网络的深度会导致模型诊断准确率下降和小样本数据诊断性能较差的问题,本文提出了基于残差 BP 神经网络的变压器故障诊断方法,所得结论如下:

(1) 所提方法在堆叠多个残差网络模块后,不仅加深了网络的层数,而且使得基于残差 BP 神经网络模型的变压器故障诊断方法具有更高的诊断准确率;

(2) 实验结果表明,本文所提基于残差 BP 神经网络的变压器故障诊断方法的诊断准确率高于基于传统深层 BP 神经网络和传统浅层 BP 神经网络的诊断方法的诊断准确率,并且所提诊断方法在小样本数据下仍具有较好的诊断效果。

## 参考文献:

[1] NING L, LIU J, QUAN C, et al. Application of the time-varying outage model of electric transmission and transforma-

tion equipment in condition-based maintenance [C] // Innovative Smart Grid Technologies-Asia (ISGT Asia). Tianjin, China: IEEE, 2012: 32-39.

- [2] 王德文, 雷倩. 基于贝叶斯正则化深度信念网络的电力变压器故障诊断方法[J]. 电力自动化设备, 2018, 38(5): 129-135.  
WANG Dewen, LEI Qian. Fault diagnosis of power transformer based on BR-DBN[J]. Electric Power Automation Equipment, 2018, 38(5): 129-135.
- [3] 郭新辰, 宋琼, 樊秀玲. 基于半监督分类方法的变压器故障诊断[J]. 高电压技术, 2013, 39(5): 1096-1100.  
GUO Xinchen, SONG Qiong, FAN Xiuling. Transformer fault diagnosis based on semi-supervised classifying method[J]. High Voltage Engineering, 2013, 39(5): 1096-1100.
- [4] 赵峰, 李硕. 基于 DGA 和改进型灰关联度模型的牵引变压器故障诊断[J]. 高压电器, 2015, 51(1): 41-45.  
ZHAO Feng, LI Shuo. Fault diagnosis for traction transformer based on DGA and improved grey correlation analysis model [J]. High Voltage Apparatus, 2015, 51(1): 41-45.
- [5] 张卫华, 苑津莎, 张铁峰, 等. 应用 B 样条理论改进的变压器三比值故障诊断方法[J]. 中国电机工程学报, 2014, 34(24): 4129-4136.  
ZHANG Weihua, YUAN Jinsha, ZHANG Tiefeng, et al. An improved three-ratio method for transformer fault diagnosis using B-spline theory[J]. Proceedings of the CSEE, 2014, 34(24): 4129-4136.
- [6] 邹剑, 陆瑾, 周晓凡. 四比值法在变压器过热性故障判断中的应用[J]. 变压器, 2011, 48(10): 66-67.
- [7] 张卫华, 苑津莎, 王杉, 等. 基于改良三比值法的变压器故障基本信度分配计算方法[J]. 电力系统保护与控制, 2015, 43(7): 115-121.  
ZHANG Weihua, YUAN Jinsha, WANG Shan, et al. A calculation method for transformer fault basic probability assignment based on improved three-ratio method[J]. Power System Protection and Control, 2015, 43(7): 115-121.
- [8] 李赢, 舒乃秋. 基于模糊聚类和完全二叉树支持向量机的变压器故障诊断[J]. 电工技术学报, 2016, 31(4): 64-70.  
LI Ying, SHU Naiqiu. Transformer fault diagnosis based on fuzzy clustering and complete binary tree support vector machine[J]. Transactions of China Electrotechnical Society, 2016, 31(4): 64-70.
- [9] 郭创新, 朱承治, 张琳, 等. 应用多分类多核学习支持向量机的变压器故障诊断方法[J]. 中国电机工程学报, 2010, 30(13): 128-134.  
GUO Chuangxin, ZHU Chengzhi, ZHANG Lin, et al. A fault diagnosis method for power transformer based on multiclass multiple-kernel learning support vector machine [J]. Proceedings of the CSEE, 2010, 30(13): 128-134.
- [10] 朱永利, 尹金良. 组合核相关向量机在电力变压器故障诊断中的应用研究[J]. 中国电机工程学报, 2013, 33(22): 68-74.  
ZHU Yongli, YIN Jinliang. Study on application of multi-kernel learning relevance vector machines in fault diagnosis of power transformers[J]. Proceedings of the CSEE, 2013, 33(22): 68-74.
- [11] 宋志杰, 王健. 模糊聚类和 LM 算法改进 BP 神经网络的变压器故障诊断[J]. 高压电器, 2013, 49(5): 54-59.  
SONG Zhijie, WANG Jian. Transformer fault diagnosis based on BP neural network optimized by fuzzy clustering and LM algorithm[J]. High Voltage Apparatus, 2013, 49(5): 54-59.
- [12] 石鑫, 朱永利, 宁晓光, 等. 基于深度自编码网络的电力变压器故障诊断[J]. 电力自动化设备, 2016, 36(5): 122-126.  
SHI Xin, ZHU Yongli, NING Xiaoguang, et al. Transformer fault diagnosis based on deep auto-encoder network[J]. Elec-

- tric Power Automation Equipment, 2016, 36(5):122-126.
- [13] 代杰杰, 宋辉, 杨祎, 等. 基于油中气体分析的变压器故障诊断 ReLU-DBN方法[J]. 电网技术, 2018, 42(2):658-664.  
DAI Jiejie, SONG Hui, YANG Yi, et al. Dissolved gas analysis of insulating oil for power transformer fault diagnosis based on ReLU-DBN[J]. Power System Technology, 2018, 42(2):658-664.
- [14] 吐松江·卡日, 高文胜, 张紫薇, 等. 基于支持向量机和遗传算法的变压器故障诊断[J]. 清华大学学报(自然科学版), 2018, 58(7):623-629.  
KARI·Tusongjiang, GAO Wensheng, ZHANG Ziwei, et al. Power transformer fault diagnosis based on a support vector machine and a genetic algorithm[J]. Journal of Tsinghua University(Science and Technology), 2018, 58(7):623-629.
- [15] 梁永亮, 郭汉琮, 薛永端. 基于特征气体关联特征的变压器故障诊断方法[J]. 高电压技术, 2019, 45(2):56-62.  
LIANG Yongliang, GUO Hancong, XUE Yongduan. Transformer fault diagnosis method based on association characteristics of characteristic gases[J]. High Voltage Engineering, 2019, 45(2):56-62.
- [16] 吴广宁, 袁海满, 宋臻杰, 等. 基于粗糙集与多类支持向量机的电力变压器故障诊断[J]. 高电压技术, 2017, 43(11):3668-3674.  
WU Guangning, YUAN Haiman, SONG Zhenjie, et al. Fault diagnosis for power transformer based on rough set and multi-class support vector machine[J]. High Voltage Engineering, 2017, 43(11):3668-3674.

#### 作者简介:



赵文清

赵文清(1973—),女,山西朔州人,教授,博士,主要研究方向为人工智能与数据挖掘(E-mail:jbzwq@126.com);

严海(1992—),男,安徽马鞍山人,硕士研究生,主要研究方向为机器学习和深度学习目标检测。

(编辑 陆丹)

## Fault diagnosis of transformer based on residual BP neural network

ZHAO Wenqing, YAN Hai, ZHOU Zhendong, SHAO Xuqiang

(School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China)

**Abstract:** The diagnostic performance of the transformer fault diagnosis method based on traditional BP neural network tends to be saturated when the network model reaches a certain depth, so it cannot further improve the diagnostic performance of the network model. In this case, deepening the depth of the network model will lead to a decline in the diagnostic performance. In addition, under the condition of small sample data, the traditional BP neural network still cannot achieve a better diagnostic accuracy. Therefore, in order to improve the diagnostic accuracy of transformer fault diagnosis and the diagnostic performance under small sample data, a transformer fault diagnosis method based on residual BP neural network is proposed. The depth of BP neural network is deepened by stacking multiple residual network modules, and the identity mapping learning of traditional BP neural network is converted into the residual learning of BP neural network. At the same time, in each residual network module, the input information of the module can be transmitted across layers within the module, so that the input information of each module can be better transmitted to the deep network, and then a better diagnosis model can be trained under the condition of small sample data. Experimental results show that, compared with the traditional deep BP neural network and the traditional shallow BP neural network, the proposed method has higher diagnostic accuracy and better diagnostic performance under small sample data.

**Key words:** power transformers; fault diagnosis; residual BP neural network; identity mapping; residual network module