

DOI:10.12158/j.2096-3203.2021.06.003

基于 Focal 损失 SSDAE 的变压器故障诊断方法

武天府, 刘征, 王志强, 李劲松, 李国锋

(大连理工大学电气工程学院, 辽宁 大连 116024)

摘要:研究变压器的故障诊断对电力系统安全稳定运行具有重大现实意义。以油中溶解气体特征为输入的传统变压器故障诊断方法在处理样本不平衡数据时具有较大的局限性。针对这一问题,文中提出一种基于 Focal 损失栈式稀疏降噪自编码器(SSDAE)的变压器故障诊断方法。该方法通过类别权重确定超参数,并在原始输入中加入高斯白噪声,有利于自编码器充分提取有效特征,进而得到有效的深度特征提取模型;采用 Focal 损失函数对模型进行优化,并利用 Softmax 分类器输出诊断结果。案例分析结果表明,与传统三比值法、反向传播神经网络(BPNN)和支持向量机(SVM)法等变压器故障诊断方法相比,文中方法可进一步提升诊断准确率。

关键词:变压器;故障诊断;栈式稀疏降噪自编码器(SSDAE);Softmax 分类器;Focal 损失;类别权重

中图分类号:TM41

文献标志码:A

文章编号:2096-3203(2021)06-0018-07

0 引言

电力变压器是电力系统运行的核心设备,准确诊断变压器内部潜伏性故障对于电网安全运行具有重要意义^[1]。油中溶解气体分析(dissolved gas analysis, DGA)是诊断和检测变压器内部潜伏性故障的有效方法^[2-3],并在此基础上形成了三比值法、改良三比值法等变压器故障诊断方法^[4-5]。此方法的基本原理是在变压器发生故障时,根据从变压器油中提取的特征气体含量算出相应的三对比值并赋予相应的编码,再由编码规则得到一组编码表,然后根据表中提供的诊断标准找到相应的故障类型。但上述方法在实践过程中逐渐显露出编码不全、判断标准过于绝对等缺点^[6]。为了克服上述弊端,国内外学者展开了深入研究,部分学者提出了基于人工智能算法的变压器故障诊断方法,如专家系统^[7]、支持向量机(support vector machine, SVM)法^[8]、模糊理论法^[9-10]、人工神经网络(artificial neural network, ANN)法^[11]等。专家系统需要大量正确的专家经验,实际应用较困难^[12];SVM 法本质上是二分类算法,变压器故障诊断为多分类问题,面对多分类问题,参数设置及构造分类器过程均较为繁琐^[13];模糊理论法需要人为设置初始聚类中心,诊断效果受初始聚类中心限制较大^[10];ANN 法存在收敛速度慢,易陷入局部最优解的缺陷^[11]。

上述变压器故障诊断方法均属于浅层机器学习方法,面对变压器故障诊断,存在学习能力不足、深层特征挖掘困难等缺点,进而影响变压器故障诊

断效果^[14]。相比于浅层学习方法,深度学习的本质是通过构造多隐藏层的神经网络,将数据进行非线性映射,可以实现对原始特征的深层挖掘及分析^[15]。自编码器(auto-encoder, AE)是深度学习的重要组成部分,在无监督学习及非线性特征提取过程中扮演着重要角色^[16]。通过堆叠多个 AE 形成栈式 AE,能够提取原始数据中更深层次的信息^[17]。

然而在针对分类问题的常见深度学习方法中,损失函数一般使用交叉熵损失,并未考虑样本不平衡对诊断结果的影响,而变压器运行及监测过程中较难获得完备样本。为此,文中提出一种基于 Focal 损失栈式稀疏降噪自编码器(stack sparse denoising auto-encoder, SSDAE)的变压器故障诊断方法。通过 Focal 损失来削弱因样本不平衡带来的不利影响。基于具体的算例进行了验证,结果表明文中方法具有良好的诊断性能。

1 SSDAE 模型

1.1 AE

AE 是一种经典的无监督网络,是实现无监督数据特征提取的一种方法。AE 输出层与输入层神经元个数相等,输入层到隐藏层的部分为编码器,而隐藏层到输出层的部分为解码器^[18],结构如图 1 所示。

设 $X = \{x_{(1)}, x_{(2)}, \dots, x_{(N)}\}$ 为无标签训练样本数据集,其中 N 为样本组数;输入层和输出层都包含 n 个神经元,输入向量为 $\mathbf{x} = (x_1, x_2, x_3, \dots, x_n)^T$,输出向量为 $\hat{\mathbf{x}} = (\hat{x}_1, \hat{x}_2, \hat{x}_3, \dots, \hat{x}_n)^T$;隐藏层包含 m 个神经元,隐藏层向量为 $\mathbf{h} = (h_1, h_2, h_3, \dots, h_m)^T$ 。

编码和解码的过程可分别由式(1)、式(2)表

收稿日期:2021-06-17;修回日期:2021-08-23

基金项目:国家自然科学基金资助项目(51907016)




图 1 AE 结构

Fig.1 AE structure

示,即:

$$\mathbf{h} = f(\mathbf{W}_1 \mathbf{x} + \mathbf{b}_1) \quad (1)$$

$$\hat{\mathbf{x}} = g(\mathbf{W}_2 \mathbf{h} + \mathbf{b}_2) \quad (2)$$

式中: $\mathbf{W}_1 \in \mathbf{R}^{n \times m}$ 为编码权重矩阵; $\mathbf{b}_1 \in \mathbf{R}^m$ 为编码偏置向量; $\mathbf{W}_2 \in \mathbf{R}^{m \times n}$ 为解码权重矩阵; $\mathbf{b}_2 \in \mathbf{R}^n$ 为解码偏置向量; $f(\cdot)$, $g(\cdot)$ 分别为编码、解码过程非线性激活函数,一般采用 Relu 函数。

1.2 栈式稀疏自编码器 (SSAE)

当 AE 中隐藏层节点数大于输入层节点数时,应对隐藏层施加一定约束。文中选择在损失函数中增加惩罚因子项,对 AE 进行稀疏性限制,进而构成稀疏自编码器 (sparse auto-encoder, SAE), SAE 的代价函数为^[18]:

$$J_{\text{sparse}}(\mathbf{W}, \mathbf{b}) = J(\mathbf{W}, \mathbf{b}) + \beta \sum_{j=1}^m K_L(\rho \parallel \hat{\rho}_j) \quad (3)$$

$$J(\mathbf{W}, \mathbf{b}) = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad (4)$$

$$K_L(\rho \parallel \hat{\rho}_j) = \rho \ln \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \ln \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (5)$$

式中: $J(\mathbf{W}, \mathbf{b})$ 为均方误差; $J_{\text{sparse}}(\mathbf{W}, \mathbf{b})$ 为改进均方误差; β 为稀疏惩罚项系数,一般可设为 0.3; m 为隐藏层神经元的数量; $K_L(\rho \parallel \hat{\rho}_j)$ 为 Kullback-Leibler 散度; $\hat{\rho}_j$ 为隐藏层神经元 j 对于所有训练数据的平均激活度; ρ 为稀疏性参数,一般可设为 0.05 或 0.1; y_i 为第 i 个样本真实标签; \hat{y}_i 为模型的输出值; \mathbf{W} 为权重矩阵; \mathbf{b} 为偏置向量。

SAE 仍为浅层学习模型,为了实现特征深度提取,可按照栈式结构对 SAE 进行堆叠,且前一层网络的输出作为后一层网络的输入,进而构建栈式稀疏自编码器 (stack sparse auto-encoder, SSAE)。

1.3 SSDAE

SSDAE 是在 SSAE 的基础上,对原始的输入数据加入噪声,将变化后的数据输入 SSAE 模型中,令

其尽可能重构一个与原始数据相同的输出。对原始输入数据增加噪声通常有 2 种方式。一种是增加一个较小的随机扰动,通常为高斯白噪声,如式(6)所示。

$$\tilde{x} = x + \mu \varepsilon \quad \varepsilon \sim N(0, 1) \quad (6)$$

式中: \tilde{x} 为加入噪声后的数据; x 为原始数据; μ 为系数; ε 为服从均值为 0, 方差为 1 正态分布的随机数。

另一种是随机把输入向量中的一部分分量按概率赋值为 0。文中选用第一种增加噪声方式,通过增加噪声,SSDAE 迫使编码器学习提取重要的特征并学习输入数据中更加鲁棒的表征,同时增加模型的泛化能力。

SSDAE 神经网络分为无监督预训练和有监督微调 2 个阶段。

(1) 无监督预训练阶段。该阶段基于无标签样本数据,利用式(3)所示的损失函数,采用逐层贪婪训练策略,利用反向传播算法,依次实现 SSDAE 各层网络参数的训练。

(2) 有监督微调阶段。该阶段去掉 SSDAE 的解码层,并加入 Softmax 分类层,基于交叉熵损失函数,利用反向传播算法对各层网络参数进行优化。其中交叉熵损失函数可由式(7)表示。

$$l = - \sum_{i=1}^N (y_i \ln \hat{y}_i) \quad (7)$$

1.4 Focal 损失函数

对于分类任务,通常采用交叉熵损失函数^[19]。文中使用的变压器故障数据样本中,正常样本所占比例大且故障类样本之间存在着不平衡,使用交叉熵损失函数会使训练后的模型向样本多的类别偏移。Focal 损失函数可以有效地解决上述问题,其公式为:

$$F = - \alpha (1 - \hat{y})^\gamma \ln \hat{y} \quad (8)$$

式中: α 为平衡参数; γ 为聚焦参数; \hat{y} 为预测标签概率。

通过增加训练样本少的类别学习强度,减少训练样本多的类别学习强度,来消除类别样本不平衡对结果的影响。文中采用文献[20]的方法,具体而言,任意 2 个类别权重之比等于这 2 个类别样本数量的反比。设数据类别总数为 N ,则第 i 类的参数 α_i 等于类别权重值,如式(9)所示。聚焦参数 γ 设置为 2^[21]。

$$\alpha_i = \frac{1}{n_i} / \sum_{i=1}^M \frac{1}{n_i} \quad (9)$$

式中: n_i 为第 i 类样本总数; α_i 为第 i 类样本的平衡

参数; M 为类别总数。

文中使用 Focal 损失函数来代替式(7),减小样本数多的类别所对应的损失权重,增大样本数少的类别所对应的损失权重,使得模型更多地关注样本数少的类别,从而提高模型对变压器故障诊断的准确率。

2 基于 Focal 损失 SSDAE 的变压器故障诊断

2.1 输入量的确定

油浸式变压器内的油/纸绝缘材料在热和电场的作用下会逐渐老化和分解,产生少量的各种低分子烃类及二氧化碳、一氧化碳等气体。若有放电和过热故障时,油中溶解气体组分和含量会随之改变,因此,一般选取氢气(H_2)、甲烷(CH_4)、乙炔(C_2H_2)、乙烯(C_2H_4)、乙烷(C_2H_6)这5种气体作为特种气体来判断变压器的故障类型。由于这5种气体含量值差异较大,为了使 SSDAE 网络有良好的收敛性,将输入数据进行归一化处理,将各种溶解气体含量换算为 $[0,1]$ 范围内的相对含量,如式(10)所示。

$$x'_i = \frac{x_i - x_{i\min}}{x_{i\max} - x_{i\min}} \quad (10)$$

式中: x'_i 为归一化后的数据; x_i 为第 i 种气体的原始浓度数据; $x_{i\min}$, $x_{i\max}$ 分别为第 i 种气体浓度的最小值和最大值。

2.2 输出量的确定

参照 IEC 60599 规定,变压器故障类型包括局部放电、低能放电、高能放电、低温过热、中温过热及高温过热。可对变压器故障状态进行 ont_hot 编码,如表 1 所示。

表 1 变压器运行状态编码

Table 1 Transformer operation status code

状态名称	符号	状态编码
正常	N	(1,0,0,0,0,0,0)
局部放电	PD	(0,1,0,0,0,0,0)
低能放电	D1	(0,0,1,0,0,0,0)
高能放电	D2	(0,0,0,1,0,0,0)
低温过热	T1	(0,0,0,0,1,0,0)
中温过热	T2	(0,0,0,0,0,1,0)
高温过热	T3	(0,0,0,0,0,0,1)

2.3 变压器故障诊断模型

变压器诊断模型输入为 H_2 、 CH_4 、 C_2H_2 、 C_2H_4 、 C_2H_6 这 5 种气体含量经过归一化后的值,首先加入解码层,以输出等于输入预训练网络参数;然后去

除解码层,加入 Softmax 分类层,模型的输出为 7 个概率值,对应变压器的 7 个运行状态,取概率最大的标签所对应的故障类型为模型诊断结果。基本结构如图 2 所示。

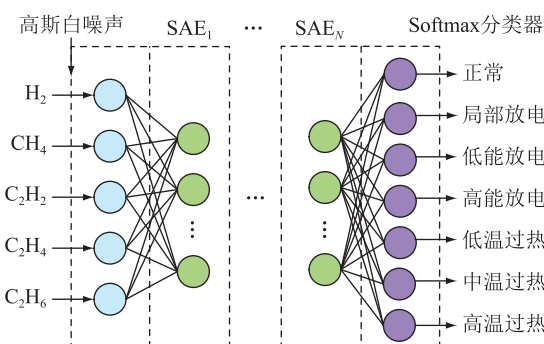


图 2 变压器故障诊断模型基本结构

Fig.2 The basic structure of transformer fault diagnosis model

建立 SSDAE 的变压器故障诊断模型需要经过 1.2 节所述 2 个训练阶段以得到最终的训练模型。为了加快训练速度,采用自适应学习率,学习率调整系数设置为 0.5,最大迭代次数为 1 000 次。

2.4 变压器故障诊断流程

基于 Focal 损失 SSDAE 的变压器故障诊断包括数据预处理、模型参数设置、无监督预训练、有监督微调 and 输出分类结果 5 个过程,其诊断流程如图 3 所示。

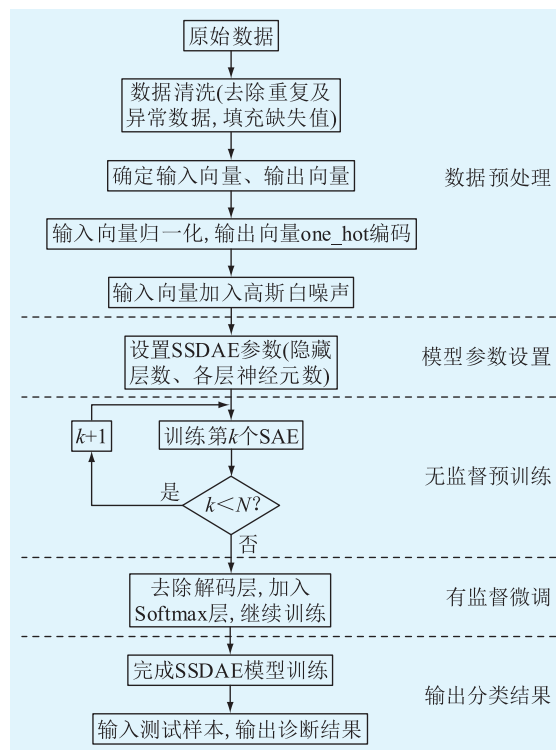


图 3 变压器故障诊断流程

Fig.3 Transformer fault diagnosis process

3 案例分析

为了验证基于 Focal 损失 SSDAE 的变压器故障诊断效果,选取某供电公司提供的变压器 DGA 故障数据,共 1 518 组。变压器的故障数据中存在人为或传感器等因素造成的重复或异常数据。重复数据会使模型更偏向于重复样本的类别,因此需进行数据去重。异常数据会使模型的准确率降低,因此使用 Tukey's test 法对异常值进行检测,执行过程如式(11)和式(12)所示^[22]。

$$U_L = Q_3 + 1.5I_{QR} \quad (11)$$

$$D_L = Q_1 - 1.5I_{QR} \quad (12)$$

式中: U_L 为上边界; D_L 为下边界; Q_1 为下四分位数,即 25%分位数; Q_3 为上四分位数,即 75%分位数; I_{QR} 为上、下四分位数差,即分位距。

异常数据的判断标准为大于上边界或小于下边界。检测到的异常数据被删除并视为缺失值。根据原始样本的 7 个状态,采用随机森林法对缺失值进行数据填充。

经过上述数据清洗,剩余 892 组非重复数据将用于后续模型的训练及结果预测。取各类样本的 80%组成训练样本集,各类样本的 20%组成测试样本集。各运行状态下训练样本及测试样本组成如表 2 所示。

表 2 故障样本统计

Table 2 Fault sample statistics

状态名称	训练样本数	测试样本数
正常	277	69
局部放电	36	9
低能放电	75	19
高能放电	111	28
低温过热	74	19
中温过热	53	13
高温过热	87	22

为了使 SSDAE 模型有较好的效果,需先明确隐藏层及神经元理想数值。文献[22]指出,当隐藏层数超过 3 层时,很难优化权重,因此文中设置隐藏层的层数为 3。隐藏层神经元的数目根据经验可由式(13)得出,对于所有的隐藏层使用相同数量的神经元个数。

$$N_h = \frac{N_s}{\alpha(N_i + N_o)} \quad (13)$$

式中: N_h 为隐藏层神经元的数目; N_s 为训练集样本数; N_i 为输入神经元的数目; N_o 为输出神经元的数目; α 为任意取值变量,通常取 1~5。由此可得到隐

藏层的神经元个数分别为 58, 29, 19, 14, 11, 进而得出网络的最佳性能,如图 4 所示。




图 4 隐藏层神经元数目对网络性能的影响

Fig.4 Influence of the number of hidden layer neurons on network performance

由图 4 可知,当隐藏层设置为 3 层,且隐藏层神经元的个数为 58 时,模型的准确率最高。据此,文中所提的 SSDAE 网络的结构为:5(输入层)—58(第一隐藏层)—58(第二隐藏层)—58(第三隐藏层)—7(输出层)。

为了确定式(6)中系数 μ 的值,分别选取了 0.001~0.01 之间的 10 个值进行计算,并与未加入高斯白噪声的模型进行对比,得到结果如图 5 所示。在加入 0.001 倍的高斯白噪声后,模型的准确率得到提升。但是,随着加入高斯白噪声的增加,模型的准确率呈现下降趋势。为了使模型达到最好的效果,文中 μ 取 0.001。




图 5 高斯白噪声对模型准确率的影响

Fig.5 Influence of Gaussian white noise on model accuracy

为明确 SSDAE 网络模型的性能,分别采用三比值法、SVM、决策树、随机森林、反向传播神经网络(back propagation neural network, BPNN)、SSAE+交叉熵损失函数和 SSDAE+交叉熵损失函数对相同的数据集进行训练和故障诊断。SVM 采用径向基函数(radial basis function, RBF)作为核函数,核函数参数设置为 0.5,正则化稀疏设置为 500;随机森林和决策树设置为默认值;BPNN 输入层为 5 个神经元,

隐藏层为 58 个神经元,输出层为 7 个神经元,输出层加 Softmax 分类器;SSAE+交叉熵损失和 SSDAE+交叉熵损失模型参数设置与文中方法一致。测试样本为 179 个,各故障诊断结果如表 3 所示,混淆矩阵的结果如图 6 所示,其中各个子图分别为各模型在变压器数据集上的混淆矩阵结果,图中色块颜色深浅仅代表数值大小。

表 3 不同方法诊断结果

Table 3 Diagnostic results of different methods

诊断方法	正确样本个数	诊断准确率
三比值	128	0.715 1
SVM	145	0.810 1
决策树	144	0.804 5
随机森林	149	0.832 4
BPNN	150	0.838 0
SSAE+交叉熵损失	159	0.888 3
SSDAE+交叉熵损失	160	0.893 9
SSDAE+Focal 损失 (文中方法)	167	0.933 0

由表 3 和图 6 结果可知:

(1) 三比值法故障编码少,部分故障用三比值法难于诊断,且三比值法的判断标准过于绝对,导

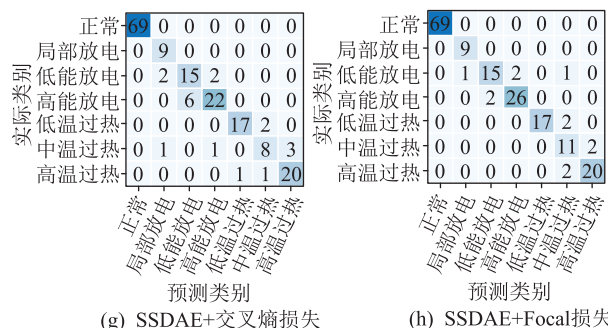
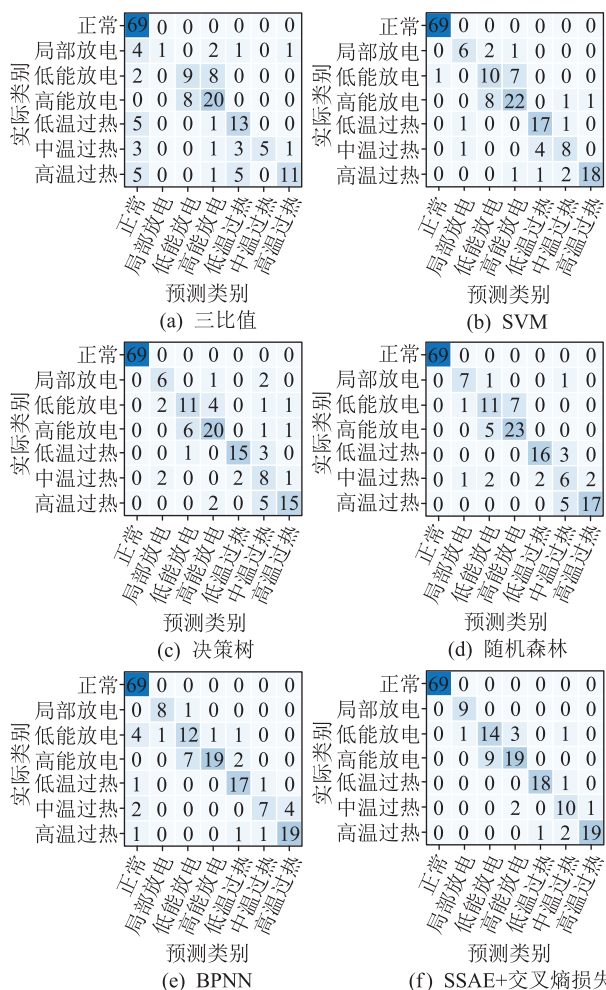


图 6 各模型在变压器数据集上的混淆矩阵

Fig.6 Confusion matrix of each model on transformer data set

致三比值法的准确率偏低。

(2) 对于深层特征的提取能力,文中方法优于传统的 SVM、决策树、随机森林和 BPNN 等浅层模型,其准确率也高于传统方法。

(3) 在 SSAE 的输入向量中加入高斯白噪声,可以避免模型的过拟合,增加了模型的泛化能力。因此 SSDAE 模型的准确率高于 SSAE 的准确率。

(4) 训练样本不平衡易造成模型产生偏向性,进而影响模型对故障的诊断效果。而在变压器的故障诊断中,样本不平衡无法避免,文中采用 Focal 损失函数可进一步降低样本不平衡的影响。

4 结论

文中分析了 SSDAE 的结构和原理,提出一种基于 Focal 损失 SSDAE,利用变压器中的 5 种特征气体含量作为模型的输入量,7 类运作状态作为输出量,经过训练得到了变压器故障诊断方法。有如下结论:

(1) SSDAE 能有效地提取数据的深层特征,且加入高斯白噪声能提升模型的泛化能力,从而提高模型分类的准确率。

(2) 在实际运行中,较难获得变压器的完备样本,主要表现为正常样本远多于故障样本且各故障类样本也存在不平衡,导致模型准确率偏低。基于 Focal 损失 SSDAE 能有效解决样本不平衡带来的准确率偏低的问题。

(3) 与传统的机器学习方法,如 SVM、决策树、随机森林和 BPNN 相比,基于 Focal 损失 SSDAE 的故障诊断方法具有更高的诊断准确率。

诊断模型的评价指标除准确性外,还有模型的稳定性。对于所提变压器故障诊断模型的稳定性文中并未涉及,有待后续研究。

本文得到中央高校基本科研业务费(DUT20RC(3)018)资助,谨此致谢!

参考文献:

- [1] 刘文泽,张俊,邓焱. 基于深度置信网络和多维信息融合的变压器故障诊断方法[J]. 电力工程技术, 2019, 38(6): 16-23.
LIU Wenze, ZHANG Jun, DENG Yan. Transformer fault diagnosis method based on deep learning and multi-dimensional information fusion[J]. Electric Power Engineering Technology, 2019, 38(6): 16-23.
- [2] 赵文清,严海,周震东,等. 基于残差 BP 神经网络的变压器故障诊断[J]. 电力自动化设备, 2020, 40(2): 143-148.
ZHAO Wenqing, YAN Hai, ZHOU Zhendong, et al. Fault diagnosis of transformer based on residual BP neural network[J]. Electric Power Automation Equipment, 2020, 40(2): 143-148.
- [3] 汪可,李金忠,张书琦,等. 变压器故障诊断用油中溶解气体新特征参量[J]. 中国电机工程学报, 2016, 36(23): 6570-6578, 6625.
WANG Ke, LI Jinzhong, ZHANG Shuqi, et al. New features derived from dissolved gas analysis for fault diagnosis of power transformers[J]. Proceedings of the CSEE, 2016, 36(23): 6570-6578, 6625.
- [4] 中华人民共和国国家质量监督检验检疫总局. 变压器油中溶解气体分析和判断导则:GB/T 7252—2001[S]. 北京:中国标准出版社, 2004.
General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China. Guide to the analysis and the diagnosis of gases dissolved in transformer oil: GB/T 7252-2001[S]. Beijing: Standards Press of China, 2004.
- [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] 许寅卿,胡炎. 基于改良三比值法的变压器故障模糊综合评判法[J]. 电力与能源, 2017, 38(2): 132-136.
XU Yinqing, HU Yan. Fuzzy comprehensive evaluation of transformer faults based on improved three-ratio method[J]. Power & Energy, 2017, 38(2): 132-136.
- [7] WANG Z Y, LIU Y L, GRIFFIN P J. A combined ANN and expert system tool for transformer fault diagnosis[J]. IEEE Transactions on Power Delivery, 1998, 13(4): 1224-1229.
- [8] 柳强,丁宇. 基于 SVM 和 Kriging 模型的变压器故障诊断方法[J]. 高压电器, 2018, 54(12): 274-280.
LIU Qiang, DING Yu. Fault diagnosis method of power transformers based on support vector machine and Kriging model[J]. High Voltage Apparatus, 2018, 54(12): 274-280.
- [9] VENKATASAMI A, LATHA P, KASIRAJAN K. Application of adaptive neuro-fuzzy inference system based on IEC method for transformer fault diagnosis[J]. International Journal of Soft Computing, 2014, 9(5): 333-337.
- [10] 刘凯,彭维捷,杨学君. 特征优化和模糊理论在变压器故障诊断中的应用[J]. 电力系统保护与控制, 2016, 44(15): 54-60.
LIU Kai, PENG Weijie, YANG Xuejun. Method of fault diagnosis for power transformer based on optimizing characteristics and the fuzzy theory[J]. Power System Protection and Control, 2016, 44(15): 54-60.
- [11] 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.
JIA Jinglong, YU Tao, WU Zijie, et al. Fault diagnosis method of transformer based on convolutional neural network[J]. Electrical Measurement & Instrumentation, 2017, 54(13): 62-67.
- [12] 陈尔奎,杜晓萍,郑帆. 基于专家系统的变压器故障诊断[J]. 控制工程, 2012, 19(S1): 133-135, 141.
CHEN Erkui, DU Xiaoping, ZHENG Fan. Fault diagnosis based on expert system for transformer[J]. Control Engineering of China, 2012, 19(S1): 133-135, 141.
- [13] GANYUN L V, CHENG H Z, ZHAI H B, et al. Fault diagnosis of power transformer based on multi-layer SVM classifier[J]. Electric Power Systems Research, 2005, 74(1): 1-7.
- [14] 王伟,唐庆华,刘力卿,等. 基于加权综合损失优化深度学习和 DGA 的变压器故障诊断方法[J]. 南方电网技术, 2020, 14(3): 29-34.
WANG Wei, TANG Qinghua, LIU Liqing, et al. Transformer fault diagnosis method based on weighted comprehensive loss optimization deep learning and DGA[J]. Southern Power System Technology, 2020, 14(3): 29-34.
- [15] 尹宝才,王文通,王立春. 深度学习研究综述[J]. 北京工业大学学报, 2015, 41(1): 48-59.
YIN Baocai, WANG Wentong, WANG Lichun. Review of deep learning[J]. Journal of Beijing University of Technology, 2015, 41(1): 48-59.
- [16] JIANG X J, ZHANG Y H, ZHANG W S, et al. A novel sparse auto-encoder for deep unsupervised learning[C]//2013 Sixth International Conference on Advanced Computational Intelligence (ICACI). Hangzhou, China. IEEE, 2013: 256-261.
- [17] 许倩文,吉兴全,张玉振,等. 基于栈式稀疏自编码器的矿用变压器故障诊断[J]. 工矿自动化, 2018, 44(10): 33-37.
XU Qianwen, JI Xingquan, ZHANG Yuzhen, et al. Fault diagnosis of mind-used transformer based on stacked sparse auto-encoder[J]. Industry and Mine Automation, 2018, 44(10): 33-37.
- [18] 孟令恒. 自动编码器相关理论研究与应用[D]. 徐州:中国矿业大学, 2017.
MENG Lingheng. Research on autoencoder and its application[D]. Xuzhou: China University of Mining and Technology, 2017.
- [19] 路志英,汪永清,孙晓磊,等. 基于 Focal Loss 改进的 GBDT 模型对天津强对流灾害的预报[J]. 灾害学, 2020, 35(3): 34-37, 50.
LU Zhiying, WANG Yongqing, SUN Xiaolei, et al. Tianjin strong convection disaster forecast based on improved GBDT

model of Focal Loss[J]. Journal of Catastrophology, 2020, 35(3):34-37, 50.

[20] 傅博文,唐向宏,肖涛. Focal 损失在图像情感分析上的应用研究[J]. 计算机工程与应用, 2020, 56(10):179-184.

FU Bowen, TANG Xianghong, XIAO Tao. Research on Focal loss function applied to image emotion analysis[J]. Computer Engineering and Applications, 2020, 56(10):179-184.

[21] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2):318-327.

[22] ABRAHAM B, NAIR M S. Computer-aided classification of prostate cancer grade groups from MRI images using texture

features and stacked sparse autoencoder [J]. Computerized Medical Imaging and Graphics, 2018, 69:60-68.

作者简介:



武天府

武天府(1993),男,硕士,研究方向为电力变压器故障诊断(E-mail:wutianfu@mail.dlut.edu.cn);

刘征(1987),男,博士,副教授,研究方向为永磁电机的设计与控制;

王志强(1983),男,博士,副教授,研究方向为电工理论与新技术。

Transformer fault diagnosis method based on Focal loss SSDAE

WU Tianfu, LIU Zheng, WANG Zhiqiang, LI Jinsong, LI Guofeng

(School of Electrical Engineering, Dalian University of Technology, Dalian 116024, China)

Abstract: It is of great practical significance to study the fault diagnosis of transformers for safe and stable operation in power systems. The traditional transformer fault diagnosis method with dissolved gas characteristics in oil as input has a large limitation in dealing with sample imbalance data. To address this problem, a transformer fault diagnosis method based on Focal loss-stacked sparse denoising auto-encoder (SSDAE) is proposed. The method is used to determine hyperparameters by category weights and adds Gaussian white noise as the original input, which facilitates the self-encoder to fully extract effective features, and thus obtaining an effective deep feature extraction model. The Focal loss function is used to optimize the model and a Softmax classifier is used to output the diagnosis results. The results of the case study show that compared with traditional transformer fault diagnosis methods such as three-ratio method, back propagation neural network (BPNN) and support vector machine (SVM) method, the method in this paper further improves the diagnosis accuracy.

Keywords: transformer; fault diagnosis; stack sparse denoising auto-encoder (SSDAE); Softmax classifier; Focal loss; category weight

(编辑 钱悦)