

基于改进神经网络与比值法融合的变压器故障诊断方法

李平, 胡根铭

(安徽理工大学电气与信息工程学院, 淮南 232001)

摘要: 为提高采用单神经网络方法的变压器故障诊断精度, 该文提出了一种基于改进神经网络与比值法融合的变压器故障诊断方法。针对深层 1 维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)难以适应变压器溶解气体数据的难题, 搭建了改进的 1D-CNN 作为融合分类方法的基础分类器; 为提升神经网络在变压器故障诊断中的应用性能, 提出了一种融合分类模块(fusion classification module, FCM), 提前筛选出可能被网络错误分类的样本并转由传统比值法进行单条数据分析; 并用算例仿真验证了所提方法的可操作性和适应性。研究表明: 与常规 1 维卷积神经网络、循环神经网络相比, 改进的 1D-CNN 作为基础分类器的性能表现优异; FCM 在不同数据集下对基础分类器均有相应的性能提升, 对于初始准确率高于 95% 的基础分类器提升效果更稳定。

关键词: 1 维卷积神经网络; 融合分类方法; 比值法; 变压器故障诊断; 溶解气体

Transformer Fault Diagnosis Method Based on the Fusion of Improved Neural Network and Ratio Method

LI Ping, HU Genming

(School of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001, China)

Abstract: In order to improve the accuracy of transformer fault diagnosis with single neural network method, a transformer fault diagnosis method based on the fusion of improved neural network and ratio method is proposed. To solve the problem of adaptation between the deep one-dimensional convolution neural network (1D-CNN) and transformer dissolved gas data, an improved 1D-CNN is built as the basic classifier of fusion classification method. A fusion classification module (FCM) is suggested to identify in advance the samples that can potentially be misclassified by the network and switch to the traditional ratio method for individual data analysis. This aims to enhance the application performance of neural networks in transformer fault diagnosis. The simulation study is given to verify the operability and adaptability of the proposed method. The results show that, compared with conventional one-dimensional convolutional neural network and recurrent neural network, the improved 1D-CNN performs better as a basic classifier. FCM can improve the performance of basic classifiers under different data sets, and the improvement effect is more stable for basic classifiers with initial accuracy higher than 95%.

Key words: one-dimensional convolutional neural network; fusion classification method; ratio method; transformer fault diagnosis; dissolved gas

0 引言

利用神经网络等人工智能方法对电力设备大数据进行深度学习和分析是电力设备智能运维领域

的发展趋势^[1]。电力变压器在电力系统中参与发电、输电、配电 3 个环节, 掌握其运行状态对保障电网稳定运行具有重要意义。目前, 油浸式电力变压器大多可通过油中溶解气体分析(dissolved gas analysis, DGA)法来检测相关气体含量表征变压器运行状态^[2-5]。基于 DGA 法, 国内外学者建立了诸如 IEC 标准比值法、Rogers 比值法和 Doernenburg 比值法等^[6-8], 这些传统方法具有操作简单、可用单

基金资助项目: 安徽省自然科学基金(2108085ME180); 安徽高校协同创新项目(GXXT-2021-024); 安徽理工大学博士科研基金(13190006)。Project supported by Anhui Provincial Natural Science Foundation (2108085ME180), University Synergy Innovation Program of Anhui Province (GXXT-2021-024), Doctoral Research Project Foundation of AUST (13190006).

条数据诊断, 但易受编码漏缺、阈值固定等限制, 因此准确率偏低^[9-10]。

随着人工智能技术的发展^[11], 神经网络因其在多个领域的优异表现, 逐渐引起业界持续关注^[12-17]。目前, 研究者针对如何将新型神经网络应用于变压器故障诊断进行了一定探索, 提出的方法主要归纳为数据和算法两个方面。数据方面以数据增强为主, 在数据不足的情况下, 文^[18-19]分别构建了条件生成对抗网络和改进的自动编码器, 生成的数据具备一定的多样性, 在一定程度上提升了故障诊断性能, 但易存在训练过程不稳定等问题, 单独应用具有一定局限性。算法方面选择合适的分类器是提升准确度的关键, 文^[19-20]分别构建了改进的卷积神经网络和图卷积神经网络作为分类器, 两者皆对卷积神经网络(convolutional neural network, CNN)进行改进, 但准确度有待进一步提升。

作为备受欢迎的新型分类模型, 1 维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)具有较强特征提取能力^[21-22], 相对于常规 CNN, 1D-CNN 的输入通常为 1 维数组, 其卷积核只在一个方向进行滑动, 理论上符合溶解气体数据特征。但溶解气体数据特征值个数较少, 很难构建深层 1D-CNN 以提升诊断的准确率, 因此改进并应用 1D-CNN 成为亟待解决的工程技术难题, 引起了国内外同行的关注。

基于神经网络的变压器故障诊断方法大多专注于研究算法本身, 通过改进结构和参数获取更高的准确率, 文献^[23]在卷积层基础上应用注意力机制对深层信息进行权重分配, 提高了诊断水平, 但这是有限的。现有研究表明, 神经网络与传统比值法分别具有诊断准确率高、可单条数据诊断的优点^[24], 如何结合二者优点以突破基于神经网络方法的变压器故障诊断在准确率提升中的有限性, 仍需开展深入研究。

针对上述存在的两个局限, 论文提出了一种基于改进神经网络与比值法融合的变压器故障诊断方法。在分析常规 1D-CNN 原理的基础上, 结合溶解气体特点搭建了改进的 1D-CNN 作为基础分类器。为结合神经网络与传统比值法的优点, 论文构建了融合分类模块作为变压器故障诊断的分类模型。论文对所建模型进行算例计算, 计算结果验证了所提方法的有效性, 研究结果可为基于神经网络的变压器故障诊断方法提供新思路。

1 改进的 1D-CNN 模型

1.1 1D-CNN 原理

2006 年, Hinton 等^[25]提出深度学习理论, CNN 因其表征学习能力而受到关注得以快速发展, 并成功应用于计算机视觉、自然语言识别等领域。对比常规 CNN, 1D-CNN 的卷积核通常只沿一个方向扫描可视特征图位置, 与变压器溶解气体的输入特征相符。图 1 给出了传统 1D-CNN 的卷积原理示意图。

图 1 中, X_i 和 X_{i+1} 分别为该层卷积层的输入和输出特征, \otimes 为 1 维卷积操作过程, F 为非线性激活函数。其中, n_{i+1} 为卷积核个数, 决定了输出特征的通道数; n_i 为输入特征通道数, 由上一层卷积核个数决定; L_i 和 L_{i+1} 分别为输入和输出特征的序列长度, 即特征值个数。 L_{i+1} 的大小受卷积参数控制, 卷积参数包括卷积核大小 f 、卷积步长 s 和填充方式 p 。图 1 中 f 和 s 分别为 3 和 1, p 为有效填充(valid padding), 即完全不填充, 卷积核只扫描能感受到的输入特征图位置, 其输出特征的序列长度为:

$$L_{i+1} = (L_i - f) / s + 1 \quad (1)$$

另一种填充方式为相同填充(same padding), 其特点为输出与输入的特征序列长度相同。

$$L_{i+1} = (L_i + 2p - f) / s + 1 \quad (2)$$

卷积层激活函数 F 一般采用 Relu 函数:

$$F(x) = \max\{0, x\} \quad (3)$$

1.2 基于改进 1D-CNN 的基础分类器

由 1.1 节分析可以看出, 虽然变压器溶解气体特征(H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2)符合传统 1D-CNN 输入要求, 理论上可以应用于故障诊断, 但在实际应用中仍存在以下 2 个难点: 1) 溶解气体仅有 5 个特征值, 较少特征值在面对传统 1D-CNN 的池化结构会导致网络欠拟合。2) 随着网络深度的增加, 可训练参数骤增, 容易发生过拟合和准确率振荡问题, 这会阻碍准确率进一步提升。鉴于此, 仍需对传统 1D-CNN 进行结构改进与训练优化。




图 1 传统 1D-CNN 卷积原理示意图

Fig.1 Schematic diagram of traditional 1D-CNN

1.2.1 模型的输入

本文采用的变压器运行状态 DGA 数据来源于文献[26-27], 包含 762 个样本, 共 7 种运行状态: 正常、低能放电、局部放电、高能放电、低温过热、中低温过热及高温过热。为保证模型学习性能, 对数据进行清洗, 使数据集中每种运行状态的样本数相同。表 1 显示了 7 种运行状态训练集和测试集的样本分布和对应的顺序编码。

本文采用 DGA 数据中的 5 种气体特征 (H₂、CH₄、C₂H₆、C₂H₄、C₂H₂) 作为输入信息, 共计 5 个特征值。为降低各特征值之间数值分散性带来的影响, 需要对 DGA 数据进行标准化处理:

$$z_i = (x_i - \bar{x}) / s \tag{4}$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \tag{5}$$

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \tag{6}$$

表 1 样本数据具体分布和编码^[26-27]

Table 1 Distribution and coding of the samples^[26-27]

状态	训练个数	测试个数	顺序编码
正常	72	18	0
低能放电	72	18	1
局部放电	72	18	2
高能放电	72	18	3
低温过热	72	18	4
中低温过热	72	18	5
高温过热	72	18	6

式中: x_i 为 DGA 数据中的第 i 个样本; z_i 为标准化样本; n 为总样本数。

本文涉及的所有仿真均在 Anaconda 平台搭建, 深度学习框架为 Tensorflow 2.4.1 和 Keras 2.4.0, 计算机硬件配置为 Intel(R) Core(TM) i7-10750H CPU @ 2.60 GHz, 32 GB。

1.2.2 模型的结构改进

图 2 给出了本文所提改进 1D-CNN 的结构示意图。与传统 1D-CNN 结构相比, 主要有以下改进:

1) 使用池改层的卷积操作替换传统池化层。传统 1D-CNN 池化层的最大池化和平均池化会因 DGA 数据特征值较少造成特征提取不完全问题, 且池化后的输出序列大小难以控制。池改层使用卷积操作完成维度下降, 加入卷积计算增强特征提取能力的同时可控制输出序列大小。

2) 每层输出进行批标准化(BatchNormalization)处理。随着网络的加深, 激活输出过大或过小的概率增加, 加入批标准化层可以有效避免梯度消失或梯度爆炸, 增强模型的拟合能力。

图 2 改进 1D-CNN 的具体结构如下: 4 个卷积层和池改层为特征提取器, 其中, 每个池改层进行 1 次维度下降, 输出序列长度减小 1 个单位, 卷积层采用相同填充方式, 不改变输出序列大小, 实现方式如图 2 结构所示。4 个卷积层和池改层的具体结构中, 除 C_m 和 S_m 外, 其余部分完全相同。其中,

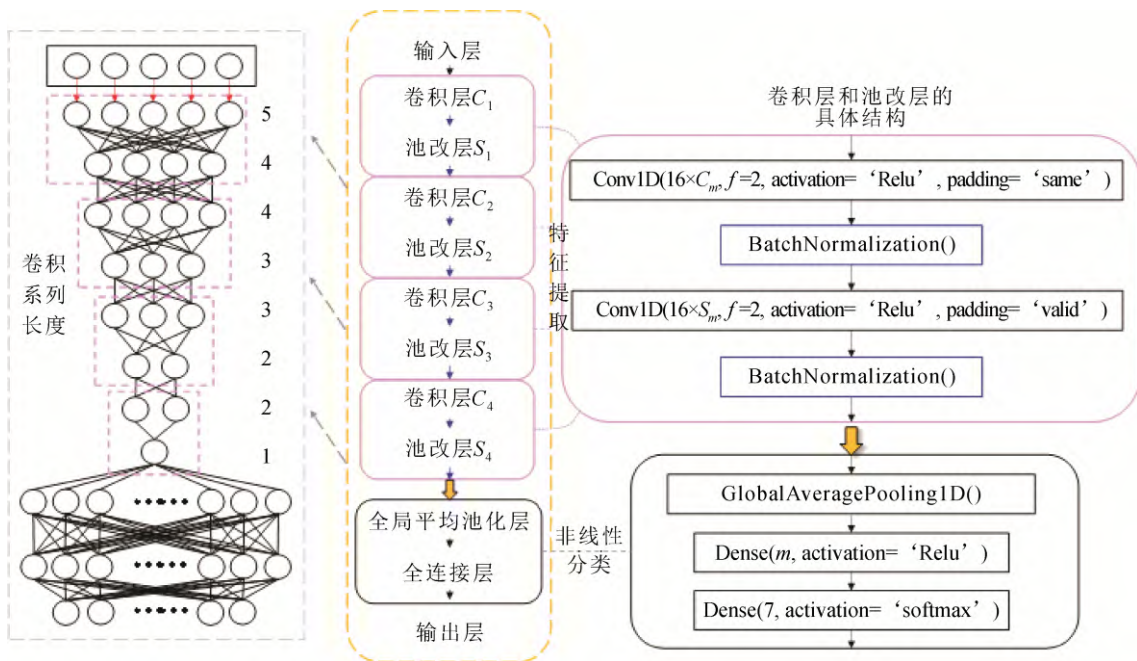


图 2 改进 1D-CNN 的结构示意图

Fig.2 Structure of improved 1D-CNN

$16C_m$ 和 $16S_m$ 分别为当前卷积层和池化层的卷积核个数; f 为卷积核大小; padding 为填充方式, 结合式(1)、式(2)可控制输出序列大小, 卷积步长 s 为默认值 1; activation 为激活函数, 卷积操作中一律采用 Relu。经过 4 次特征提取后, DAG 数据的序列长度由 5 变为 1, 此时输入全局平均池化层进行维度转换, 经过全连接层进行非线性变换, 其中, m 为全连接层当前层神经元个数, 激活函数采用 Relu。输出层中因变压器共 7 种运行状态, 故神经元个数设置为 7, 激活采用 Softmax 进行多分类。Softmax 函数又称归一化指数函数, 目的是将多分类结果以概率形式表现, 其计算式为:

$$\sigma_j = e^{z_j} / \sum_{k=1}^K e^{z_k}, j=1, \dots, K \quad (7)$$

式中: σ_j 为第 j 个神经元的激活输出; z_j 为第 j 个神经元激活前输出; K 为输出层神经元总个数。

1.2.3 模型的训练优化

为提升网络性能, 针对构建的改进 1D-CNN 进行如下优化:

1) 动态衰减学习率。考虑到理想学习率应在训练初期加快收敛速度, 随后适当衰减, 以免梯度无法下降导致准确率振荡。本文在 Adam 算法基础上采用学习率动态衰减策略, 动态学习率计算式为:

$$\alpha_t = \alpha_0 \beta^{0.1t} \quad (8)$$

式中: t 为当前迭代次数; α_t 为当前学习率; α_0 为初始学习率, 设置为 0.01; β 为衰减率, 这里设置为 0.96。

2) 使用 Dropout 方法防止过拟合。在全连接层中, 加入 Dropout 层阻断部分神经元连接使其不被激活, 随机改变网络的连接方式。

1.3 基础分类器的训练

为测试改进 1D-CNN 作为基础分类器的可行性, 以变压器溶解气体数据为输入, 对所提模型进行训练。图 3 展示了整个改进 1D-CNN 的训练过程, 其中包含训练集准确率和测试集准确率随迭代次数变化的曲线。

由图 3 可知, 在训练初期训练集准确率随迭代次数迅速上升, 测试集准确率随迭代次数缓慢上升。当训练次数大于 1000 时, 准确率趋于一个值, 这说明模型已基本收敛。结果显示, 改进 1D-CNN 的训练集准确率为 96.03%, 测试集准确率为 92.86%, 说明改进 1D-CNN 作为融合分类方法的基础分类器具有可操作性。为减小训练模型的工作量, 在确保

模型收敛的情况下, 后续工作将训练次数由 2000 个循环替换为 1500 个循环, 同时将训练完毕的改进 1D-CNN 作为预训练网络并入融合分类模块。

2 基于融合分类的变压器故障诊断模型

2.1 模型的原理及结构

针对多分类问题, 神经网络常采用 Softmax 函数对顶层输出进行激活, 其原理如图 4 所示。Softmax 以归一化的方式将顶层输出映射为对应类别被取到的概率值, 其形状为一个长度等于类别总数的张量。在模型评估中取该张量最大值位置索引作为分类结果, 以编码形式展现变压器运行状态。

既然激活输出为概率值, 说明输出张量中最大值越大, 网络对决策结果越确定; 相反, 如果输出张量中最大值较小甚至有两个值接近相同, 则很难做出正确的判断, 说明此时网络没有很好地学习到该样本特征。假如能够选择一个合适的阈值, 挑选出上述难以被网络正确识别的样本并加以单独修正, 对神经网络的应用具有一定改进效果。




图 3 改进 1D-CNN 的训练过程

Fig.3 Training process of improved 1D-CNN

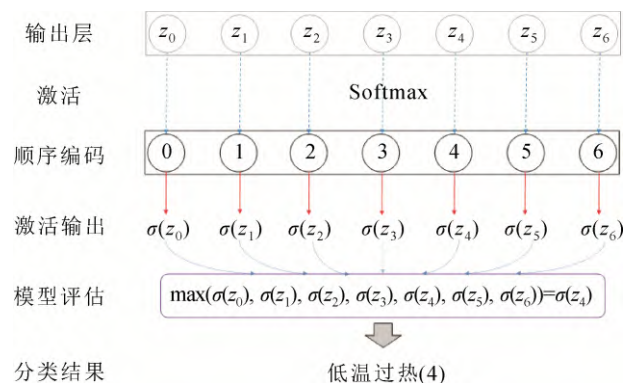


图 4 Softmax 函数原理示意图

Fig.4 Schematic diagram of Softmax function

为解决上述局限，本文构建了一种融合分类模块(fusion classification module, FCM)，以改进神经网络在变压器故障诊断中的应用。FCM 是一种融合分类模型，根据概率值预先筛选出可能被神经网络错误分类的样本，利用传统比值法可单条数据诊断的特性对筛选出的样本进行重新诊断，最终与神经网络中表现良好的样本共同输出，图 5 给出了 FCM 的具体结构。

图 5 中，考虑到神经网络和 IEC 标准比值法^[6]对数据的要求不同，其输入分别为标准化 DGA 数据 Z' 和原始数据中的第 i 个样本 Z_i ； σ_{\max} 为预训练神经网络顶层 Softmax 函数输出张量中的最大值，以 σ_{\max} 为阈值进行融合分类； k 为 0~100 的整数，0.01 k 与 σ_{\max} 的取值均在 0~1 区间，表示判定输出某种状态可能性的概率； β_i 为当前分支下第 i 个样本的诊断结果，其与真实样本 Z_i 计算可得模型准确率 a_k ，计算式为：

$$a_k = \frac{s - \sum_{i=1}^s \left(\frac{\beta_i - Z_i}{\beta_i - Z_i} \right)}{s} \times 100\%, \beta_i \neq Z_i \quad (9)$$

式中： s 为诊断样本总数； β_i 和 Z_i 分别为模型诊断结果和样本真实类别，均以表 1 中的顺序编码形式输出。

图 5 中， a 、 b 、 c 为溶解气体分析法中两种特征气体体积分数的相对比值。 a_k 为 FCM 中阈值判定为 k 时的模型准确率，如 $k=60$ 时，FCM 的诊断准确率记为 a_{60} 。阈值 k 为超参数，因 FCM 使用训练好的改进 1D-CNN 和 IEC 比值法直接输出诊断结果，其中不存在单独训练过程，故需在输入数据之前将 k 值设置完毕。

为找到 k 的最佳取值范围，使 FCM 兼顾提升神经网络诊断能力的同时，不会受 IEC 标准比值法准确率的影响，导致 FCM 整体性能下降。分别记录当 $k=1, 2, 3, \dots, 95$ 时对应输出的 a_k ，以研究 k 与 a_k 之间的关系，记录结果如图 6 所示。

由图 6 可知，当 k 较小时， a_k 维持在 0.9286 不变，这是由于所有样本都经神经网络进行诊断。当 k 较大时，过多的样本经诊断准确率较低的比值法诊断，导致 a_k 急剧下降。可以观察到，当 k 保持在约 40~70 之间时，FCM 对于神经网络的分类性能具有提升效果，其中 k 在 65 左右时提升效果最好， a_{65} 为 0.9444。根据上述实验，本文以 $k=65$ 为基准，设立 a_{65} 为评价指标，搭建 FCM 模型以改进神经网络

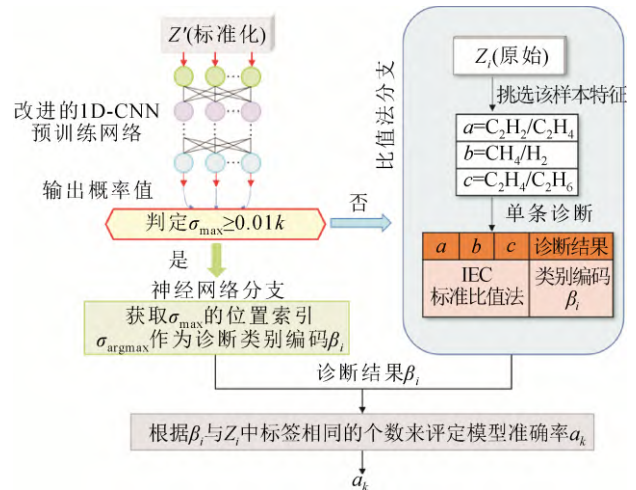


图 5 FCM 具体结构

Fig.5 The concrete structure of FCM




图 6 k 与 a_k 之间的对应关系

Fig.6 The correspondence between k and a_k

在变压器故障诊断中的应用。

2.2 模型的流程

结合以上分析，基于改进神经网络与比值法融合的变压器故障诊断流程如图 7。具体过程如下：

1) 导入数据并预处理

导入的 DGA 数据以 5 种溶解气体含量作为特征值，按比例将其划分为训练集和测试集。图 7 中 IVAE 为改进变分自编码器，用以对数据进行增强。其中输入改进 1D-CNN 的数据集进行标准化处理，输入 IEC 比值法的数据集保留原始特性。

2) 训练基础分类器

改进 1D-CNN 的输入为标准化后的训练集和测试集，训练时输出为表 1 中的顺序编码，由编码来判定其运行状态。经多次实验，得出改进 1D-CNN 的参数和结构如下：优化器是 RMSprop 算法，损失

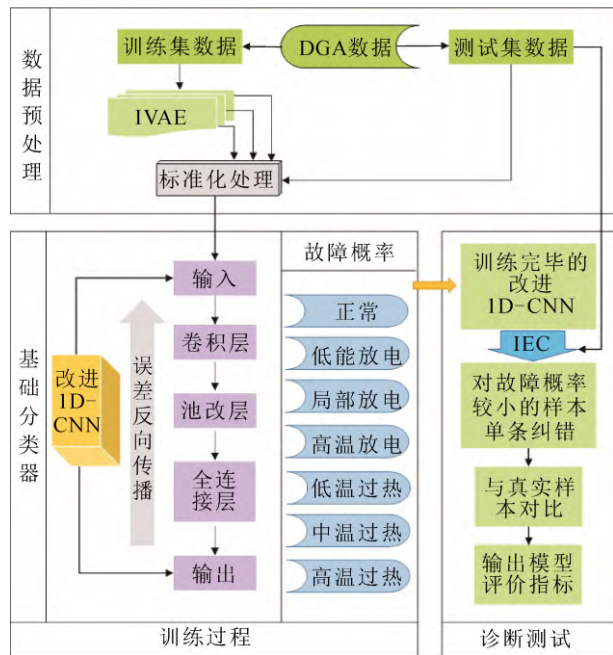


图7 所提方法的整体流程图

Fig.7 The overall process of the proposed method

函数是 `sparse_categorical_crossentropy`, 采用动态衰减学习率对模型进行优化训练。输入层和输出层的神经元个数分别为 16 和 7, 中间隐藏层 4 个卷积层的神经元个数分别为 16、32、64、128, 4 个池改层的神经元个数分别为 16、32、64、128, 5 个全连接层神经元个数分别为 128、64、32、16、8, 并加入 1 层 Dropout 层来避免过拟合。激活函数除了输出层是 Softmax, 其余都是 Relu。训练中迭代次数为 1500, 结束时统计准确率(Accuracy)和损失值(Loss)作为基础分类器的评价指标。

3) 利用 IEC 比值法进行二次诊断

诊断测试中, 训练完毕的改进 1D-CNN 输入为测试集数据, 输出为故障概率。本文对可能被算法错误分类的样本定义为“故障概率”低的样本, 对可能被算法正确分类的样本定义为“故障概率”高的样本。对于故障概率低的样本, 即有可能被网络错误分类, 此时转由 IEC 标准比值法对其单条诊断。最终将所有诊断结果与真实样本对比, 输出模型评价指标。

3 算例计算

所有原始数据来自表 1 中的 630 个实际样本, 包括 504 个训练样本和 126 个测试样本, 所有测试数据均为表 1 中的 126 个实际测试样本。为确保对比实验的有效性, 作为同一对照组的所有神经网络

模型都使用相同的输入数据。

对于 IEC 标准比值法, 本文采用阈值设定法进行分类诊断^[6], 对象为表 1 中的 126 个测试样本, 实现方式为 Python 语言的分支结构, 其中正常运行状态和其他情况均设定为正常。本文所用 126 条测试样本经 IEC 比值法诊断的结果为: 诊断正确样本数 69 个, 诊断错误样本数 57 个, 该组数据的诊断准确率为 54.76%。

3.1 不同分类器的性能对比

为证明改进 1D-CNN 作为基础分类器的有效性, 以当前主流分类模型循环神经网络(RNN)、1D-CNN 为基准, 比较不同分类器的性能。在模型可行性的前提下, 应尽量保持各模型的结构参数及规模相接近。经实验测试, 确定各分类模型的结构和参数如下:

对于常规 1D-CNN, 仅将 4 个池改层替换为 4 层常规池化层, 池化层中的 `pool_size` 两个设置为 2, 另两个设置为 1, 其余结构和参数均不变。对于 RNN, 其结构为双层长短时记忆网络(LSTM), 神经元数量分别为 512 和 256, 第 3 层为输出层神经元个数为 7, 激活函数为 Softmax, 优化器是 Adam, 其余参数不变。分别对 RNN、1D-CNN、改进 1D-CNN 进行独立重复训练 5 次, 训练次数均为 1500 个循环, 表 2 给出了不同基础分类器训练集和测试集的评估指数均值。

对表 2 中评估指数进行分析, 结果如下: 1) 相比常规 1D-CNN, 改进 1D-CNN 具有更高的诊断准确率, 在测试集中提升了 5.56%。这说明改进后的 1D-CNN 具有更好的表现, 更适合用于变压器故障分析。2) 对比各模型在训练集和测试集中的表现, 1D-CNN 性能优于 RNN, 这是因为 1D-CNN 更善于处理数值型数据, 说明基于 1D-CNN 的改进 1D-CNN 在分析溶解气体数据时更具优势。3) 对比同一模型的训练集和测试集准确率, 发现测试集准确率为训练集有一定偏差, 这可能是数据不足造成的, 故在后续比较中考虑增加训练集样本个数, 以充分发挥模型性能。

3.2 融合分类对不同分类器的适应能力

为测试本文搭建的 FCM 对不同基础分类器的适应性, 以上述分类器(RNN、1D-CNN)为基准, 比较不同分类器在结合 FCM 前、后的性能。考虑到训练样本个数对分类器性能有一定影响, 为充分测试分类器性能, 采用数据增强方法^[19]对训练集进行

各类别等量扩充至 2016 个样本,测试集样本保持不变。表 3 记录了各分类器在不同数据集下结合 FCM 进行独立重复实验 10 次后的测试集准确率均值,并与未结合 FCM 的基础分类器作对比。

由表 3 对比结果可以得出: 1) FCM 不仅对本文构建的改进 1D-CNN 具有优化效果,在其他分类器中也具有一定的适应性。2) 纵向对比,初始准确率较低的分类器在结合 FCM 后也许有更大的提升空间,但该结论是在初始准确率最低为 0.8571 的前提下提出的。对于初始精度过低的基础分类器,融合后可能提升效果不明显。这是因为此时 FCM 中由 IEC 比值法判定的样本增多,导致整体准确率下降。3) 对比表中 2 个加粗结果可以发现,常规 1D-CNN 结合 FCM 后准确率提升甚微,这可能是融合分类方法诊断错误的样本数与初始结果相近造成的,说明 FCM 的实际优化效果与其初始基础分类器之间存在一定的联系,需展开进一步研究。

3.3 融合分类在不同基础分类器上的优化效果

为进一步研究 FCM 的实际优化效果与被其优化的基础分类器之间的关系,研究何种情况下 FCM 更易成功筛选出可能被神经网络错误分类的样本并予以纠错,定义了 3 个参数进行定量分析: 1) 未结合 FCM 下基础分类器初始诊断错误的样本数 N_{ode} ; 2) 由 FCM 中比值法分支诊断的样本数 N_{IEC} ; 3) 结合 FCM 后模型最终诊断错误的样本数 N_{ude} 。选取 N_{ode} 和 N_{IEC} 是为研究不同情况下 FCM 筛选出的样本分布规律,理想情况下 N_{ode} 与 N_{IEC} 应相同,说明此时 FCM 已成功筛选出可能被神经网络错误分类的样本并转由 IEC 标准比值法诊断;选取 N_{ude} 是为追加验证 FCM 的提升性能,侧面反应 N_{ode} 和 N_{IEC} 的有效性。为充分观察潜在关系,增加实验对照组,分别将表 3 中 10 组增强数据以梯度式划分,每组随机取出 504、1008、1512、2016 个训练样本,对 RNN、1D-CNN、改进 1D-CNN 进行 1500 次循环训练,并均以 126 个实际样本进行测试。表 4 记录了对应基础分类器测试集初始准确率、结合 FCM 后提升的准确率及上述 3 个参数 N_{ode} 、 N_{IEC} 、 N_{ude} 的取整均值。

根据表 4 结果分析可知: 1) 基础分类器初始准确率越高,经 IEC 比值法诊断的样本数越接近初始诊断错误的样本数,这说明 FCM 在初始准确率较高的基础分类器中具有更稳定的优化效果,筛选出的样本更接近真实诊断错误的样本。2) 对比各模型提升的准确率,初始准确率较低的基础分类器虽

表 2 不同基础分类器的故障诊断结果

Table 2 Fault diagnosis results of different basic classifiers

数据集	分类器	准确率	损失值
训练集	RNN	0.8968	0.5971
	1D-CNN	0.9365	0.3596
	改进 1D-CNN	0.9603	0.2210
测试集	RNN	0.8571	0.6032
	1D-CNN	0.8730	0.4782
	改进 1D-CNN	0.9286	0.3226

表 3 FCM 在不同基础分类器中的性能表现

Table 3 Performance of FCM in basic classifiers

分类器	准确率		
	原始数据	增强数据 ^[19]	
基础分类器	RNN	0.8571	0.8889
	1D-CNN	0.8730	0.9127
	改进 1D-CNN	0.9286	0.9524
结合 FCM	RNN	0.8968	0.9126
	1D-CNN	0.8754	0.9286
	改进 1D-CNN	0.9444	0.9682

表 4 FCM 对不同分类器的优化效果

Table 4 Optimization effect of FCM on each classifier

训练样本数	分类器	参数分布			初始准确率	提升准确率
		N_{IEC}	N_{ode}	N_{ude}		
504	RNN	22	18	13	0.8571	0.0397
	1D-CNN	23	16	16	0.8730	0.0024
	改进 1D-CNN	12	9	7	0.9286	0.0158
1008	RNN	21	17	12	0.8651	0.0397
	1D-CNN	22	15	11	0.8809	0.0318
	改进 1D-CNN	9	7	5	0.9444	0.0158
1512	RNN	19	16	12	0.8730	0.0318
	1D-CNN	15	11	10	0.9127	0.0079
	改进 1D-CNN	7	6	4	0.9524	0.0158
2016	RNN	18	14	11	0.8889	0.0237
	1D-CNN	14	11	9	0.9127	0.0158
	改进 1D-CNN	6	6	4	0.9524	0.0158

然提升较为明显,但也存在零提升现象,这说明 FCM 对表 4 中初始准确率较低的分类器具有优化效果,但缺乏稳定性。3) 对比表 4 中 2 条加粗的结果发现,不同数据集下 FCM 对 1D-CNN 准确率的提升有差异,这可能是由于 FCM 的阈值 k 是由单一数据集训练输出造成的,说明不同数据集对阈值 k 具有一定的影响,仍需进一步研究。

3.4 融合分类在不同数据集下的适应能力

为进一步研究 FCM 的阈值 k 在不同情况下的

适应性, 在创建并使用了不同的数据集下, 寻找阈值 k 的最佳取值范围以获得尽可能高的准确率, 本文依次设定训练集样本数为 504、1008、1512、2016, 分别以 RNN、1D-CNN 和改进 1D-CNN 为基础分类器, 记录当 $k=1, 2, 3, \dots, 95$ 时对应的准确率 a_k , 记录结果如图 8 所示。

对比图 8 中的不同情况, 可以发现: 1) 在不同训练数据集下, 设置的阈值 k 在 40~70 之间对基

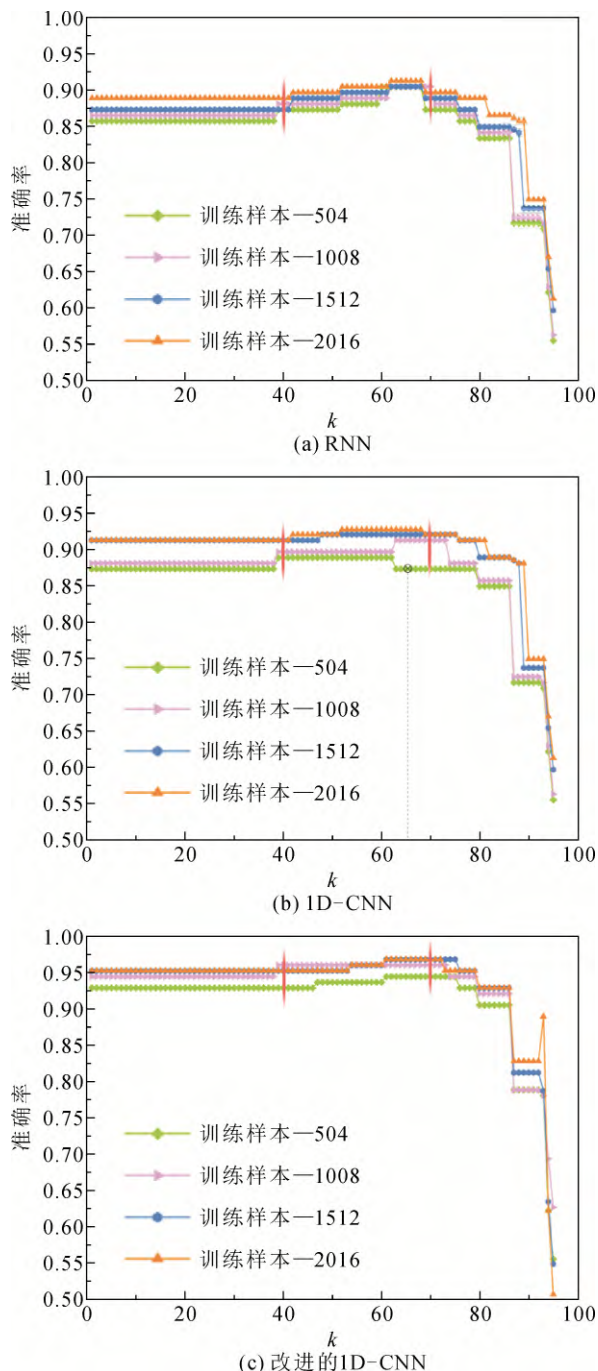


图 8 多种情况下 FCM 的优化结果

Fig.8 The optimization results of FCM under various conditions

础分类器有不同程度的提升效果, 这说明 FCM 可以有效提升变压器故障诊断的准确率, 对于不同情况也具备一定的适应性, 其在改进的 1D-CNN 中适应性最好。2) 将表 4 与图 8(b) 结合对比发现, 阈值 k 为 65 时, 1D-CNN 在不同数据集下提升的准确率不同, 说明阈值 k 在 40~70 之间具有提升效果, 但最佳提升效果还需具体分析。3) 为发挥 FCM 的最佳提升性能, 可根据具体电力变压器设备进行针对性训练, 以获得更高故障诊断准确率。

4 结论

1) 针对变压器溶解气体数据特征值较少难以与 1D-CNN 契合的难题, 本文搭建了一种改进的 1D-CNN 基础分类器。构建池改层替代传统池化层以适应特征值个数, 在每次卷积操作后进行归一化以增强网络的训练能力。与 RNN、1D-CNN 相比, 改进 1D-CNN 对于变压器溶解气体数据具有更高的分类准确率。

2) 为提升变压器故障分析的诊断性能, 提出了一种融合分类方法提前筛选出可能被神经网络错误分类的样本, 并转由 IEC 比值法进行单条样本诊断。实验结果表明: FCM 在不同数据集下对基础分类器都有一定的性能提升, 对于初始准确率较高的基础分类器提升效果较稳定。

在未来工作中, 融合分类方法适合应用于初始准确率较高的分类器, 尝试性能再优化。此外, 可以考虑提升比值法的性能, 以提高 FCM 逐条样本诊断的准确率。尝试融合新方法时应注意及时调整 FCM 中的阈值 k 以处理融合的协调性问题。

参考文献 References

- [1] 刘云鹏, 和家慧, 许自强, 等. 基于 SVM SMOTE 的电力变压器故障样本均衡化方法[J]. 高电压技术, 2020, 46(7): 2522-2529. LIU Yunpeng, HE Jiahui, XU Ziqiang, et al. Equalization method of power transformer fault sample based on SVM SMOTE[J]. High Voltage Engineering, 2020, 46(7): 2522-2529.
- [2] LI J Z, ZHANG Q G, WANG K, et al. Optimal dissolved gas ratios selected by genetic algorithm for power transformer fault diagnosis based on support vector machine[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2016, 23(2): 1198-1206.
- [3] 谢国民, 倪乐水, 曹媛. 基于 VSRP 与 β -GWO-SVM 的变压器故障辨识方法[J]. 高电压技术, 2021, 47(10): 3635-3641. XIE Guomin, NI Leshui, CAO Yuan. Transformer fault identification method based on VSRP and β -GWO-SVM[J]. High Voltage Engineering, 2021, 47(10): 3635-3641.
- [4] 康佳宇, 张沈习, 张庆平, 等. 基于 ANOVA 和 BO-SVM 的变压器故障诊断方法[J]. 高电压技术, 2023, 49(5): 1882-1891. KANG Jiayu, ZHANG Shenxi, ZHANG Qingqing, et al. Fault diagnosis method of transformer based on ANOVA and BO-SVM[J].

- High Voltage Engineering, 2023, 49(5): 1882-1891.
- [5] 廖才波, 杨金鑫, 胡雄, 等. 数据与经验混合驱动下的变压器故障分层诊断方法[J]. 高电压技术, 2023, 49(5): 1841-1850.
LIAO Caibo, YANG Jinxin, HU Xiong, et al. Hierarchical diagnosis method for transformer faults driven by mixed data and experience[J]. High Voltage Engineering, 2023, 49(5): 1841-1850.
- [6] Mineral oil-filled electrical equipment in service-guidance on the interpretation of dissolved and free gases analysis: IEC 60599 Ed. 3.0 b: 2015[S], 2015.
- [7] TAHA I B M, HOBALLAH A, GHONEIM S S M, et al. Optimal ratio limits of rogers' four-ratios and IEC 60599 code methods using particle swarm optimization fuzzy-logic approach[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2020, 27(1): 222-230.
- [8] SOUAHLIA S, BACHA K, CHAARI A. MLP neural network-based decision for power transformers fault diagnosis using an improved combination of Rogers and Doernenburg ratios DGA[J]. International Journal of Electrical Power and Energy Systems, 2012, 43(1): 1346-1353.
- [9] 江秀臣, 盛戈皞. 电力设备状态大数据分析的研究和应用[J]. 高电压技术, 2018, 44(4): 1041-1050.
JIANG Xiuchen, SHENG Gehao. Research and application of big data analysis of power equipment condition[J]. High Voltage Engineering, 2018, 44(4): 1041-1050.
- [10] SARKAR S, SHARMA T, BARAL A, et al. An expert system approach for transformer insulation diagnosis combining conventional diagnostic tests and PDC, RVM data[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2014, 21(2): 882-891.
- [11] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep learning[M]. Massachusetts, USA: MIT Press, 2016: 1-26.
- [12] 赵恺, 石立宝. 基于改进一维卷积神经网络的电力系统暂态稳定评估[J]. 电网技术, 2021, 45(8): 2945-2954.
ZHAO Kai, SHI Libao. Transient stability assessment of power system based on improved one-dimensional convolutional neural network[J]. Power System Technology, 2021, 45(8): 2945-2954.
- [13] 何成兵, 王润泽, 张霄翔. 基于改进一维卷积神经网络的汽轮发电机轴系扭振模态参数辨识[J]. 中国电机工程学报, 2020, 40(增刊 1): 195-203.
HE Chengbing, WANG Runze, ZHANG Xiaoxiang. Modal parameters identification of torsional vibration of turbogenerator shafting based on improved one-dimensional convolution neural network[J]. Proceedings of the CSEE, 2020, 40(Supplement 1): 195-203.
- [14] NAJMAEI N, KERMANI M R. Applications of artificial intelligence in safe human-robot interactions[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2011, 41(2): 448-459.
- [15] KARMAKAR G, CHOWDHURY A, DAS R, et al. Assessing trust level of a driverless car using deep learning[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(7): 4457-4466.
- [16] LIU S K, LIU L H, FAN Y P, et al. An integrated scheme for online dynamic security assessment based on partial mutual information and iterated random forest[J]. IEEE Transactions on Smart Grid, 2020, 11(4): 3606-3619.
- [17] 杨德昌, 廖文龙, 任翔, 等. 基于胶囊网络的电力变压器故障诊断[J]. 高电压技术, 2021, 47(2): 415-424.
YANG Dechang, LIAO Wenlong, REN Xiang, et al. Fault diagnosis of transformer based on capsule network[J]. High Voltage Engineering, 2021, 47(2): 415-424.
- [18] 刘云鹏, 许自强, 和家慧, 等. 基于条件式 Wasserstein 生成对抗网络的电力变压器故障样本增强技术[J]. 电网技术, 2020, 44(4): 1505-1513.
LIU Yunpeng, XU Ziqiang, HE Jiahui, et al. Data augmentation method for power transformer fault diagnosis based on conditional Wasserstein generative adversarial network[J]. Power System Technology, 2020, 44(4): 1505-1513.
- [19] 葛磊蛟, 廖文龙, 王煜森, 等. 数据不足条件下基于改进自动编码器的变压器故障数据增强方法[J]. 电工技术学报, 2021, 36(增刊 1): 84-94.
GE Leijiao, LIAO Wenlong, WANG Yusen, et al. Data augmentation method for transformer fault based on improved auto-encoder under the condition of insufficient data[J]. Transactions of China Electrotechnical Society, 2021, 36(Supplement 1): 84-94.
- [20] LIAO W L, YANG D C, WANG Y S, et al. Fault diagnosis of power transformers using graph convolutional network[J]. CSEE Journal of Power and Energy Systems, 2021, 7(2): 241-249.
- [21] YU J B, ZHOU X K. One-dimensional residual convolutional autoencoder based feature learning for gearbox fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020, 16(10): 6347-6358.
- [22] FERGUS P, CHALMERS C, MONTANEZ C C, et al. Modelling segmented cardiocography time-series signals using one-dimensional convolutional neural networks for the early detection of abnormal birth outcomes[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2021, 5(6): 882-892.
- [23] REN F L, JIANG Z W, WANG X R, et al. A DGA domain names detection modeling method based on integrating an attention mechanism and deep neural network[J]. Cybersecurity, 2020, 3(1): 1-13.
- [24] FAIZ J, SOLEIMANI M. Assessment of computational intelligence and conventional dissolved gas analysis methods for transformer fault diagnosis[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2018, 25(5): 1798-1806.
- [25] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [26] 尹金良. 基于相关向量机的油浸式电力变压器故障诊断方法研究[D]. 保定: 华北电力大学, 2013.
YIN Jinliang. Study on oil-immersed power transformer fault diagnosis based on relevance vector machine[D]. Baoding, China: North China Electric Power University, 2013.
- [27] DUVAL M, DEPABLA A. Interpretation of gas-in-oil analysis using new IEC publication 60599 and IEC TC 10 databases[J]. IEEE Electrical Insulation Magazine, 2001, 17(2): 31-41.



LI Ping

Ph.D.

Associate professor
Corresponding author

HU Genming

李平(通信作者)

1981—, 男, 博士, 副教授, 硕导

主要从事放电与等离子体技术及应用、电力设备状态感知及人工智能的应用等方面的研究工作, 主持国家自然科学基金项目 1 项、安徽省自然科学基金项目 1 项、安徽省高校协同创新项目 1 项及其他省部级项目多项

E-mail: kunguoli@126.com

胡根铭

1997—, 男, 硕士生

主要从事电力设备状态感知及人工智能应用方面的研究工作

E-mail: 1748725880@qq.com

收稿日期 2022-05-09 修回日期 2023-07-04 编辑 卫李静