

# 基于多尺度卷积神经网络的变压器故障诊断方法

王辉东<sup>1</sup>, 姚海燕<sup>1</sup>, 郭强<sup>2</sup>, 俞啸玲<sup>1</sup>, 张旭峰<sup>2</sup>, 丛龙坤<sup>3</sup>

(1. 国网浙江省电力有限公司杭州市余杭区供电公司, 浙江 杭州 311100; 2. 杭州电力设备制造有限公司余杭群力成套电气制造分公司, 浙江 杭州 311100; 3. 东北电力大学机械工程学院, 吉林 吉林 132011)

**摘要:** 为了提高变压器故障识别的诊断精度, 提出一种基于多尺度卷积神经网络模型的变压器故障诊断方法。首先, 在 1DCNN 结构基础上设计 2 个多尺度卷积模块, 构造变压器故障识别模型的总体结构。其次, 针对样本特征较少问题, 采用基于比值法的特征扩充方法, 将样本特征由 5 维增强至 25 维; 针对故障样本量少以及故障间样本数分布不平衡问题, 采用基于对抗生成网络的样本数增强方法, 生成大量模拟样本。最后, 利用改造后的数据集对所设计的模型进行训练与测试。结果表明, 模型平均准确率为 93.24%, 与相关主流方法在不同数据集下实验对比, 本模型表现效果良好。

**关键词:** 变压器; 故障诊断; 油中溶解气体; 比值法; 多尺度卷积神经网络; 对抗生成网络

DOI: 10.19781/j.issn.1673-9140.2023.04.011 中图分类号: TM411 文章编号: 1673-9140(2023)04-0104-09

## A transformer fault diagnosis method based on multiscale 1DCNN

WANG Huidong<sup>1</sup>, YAO Haiyan<sup>1</sup>, GUO Qiang<sup>2</sup>, YU Xiaoling<sup>1</sup>, ZHANG Xufeng<sup>2</sup>, CONG Longkun<sup>3</sup>

(1. Yuhang District Power Supply Company, State Grid Zhejiang Electric Power Co., Ltd., Hangzhou 311100, China; 2. Yuhang Qunli Complete Electric Manufacturing Branch, Hangzhou Electric Power Equipment Manufacturing Co., Ltd., Hangzhou 311100, China; 3. School of Mechanical Engineering, Northeast Electric Power University, Jilin 132011, China)

**Abstract:** In order to improve the diagnostic accuracy of transformer fault, a transformer fault diagnosis method based on the multi-scale convolutional neural network model is proposed. Firstly, two multi-scale convolutional modules are designed on the basis of the 1DCNN structure, and the overall structure of the transformer fault identification model is constructed. Secondly, to handle the problem of less sample features, the feature expansion method based on the ratio method is adopted to enhance the sample features from 5 dimensions to 25 dimensions. To solve the small sample size of faults and uneven distribution of sample numbers between faults, a sample number enhancement method based on adversarial generation network is adopted, and a large number of simulated samples are generated. Finally, the modified dataset was used to train and test the designed model. The results show that the average accuracy of the model is 93.24%, and the model performs well compared with the relevant mainstream methods under different datasets.

**Key words:** transformer; fault diagnosis; dissolved gas in oil; ratio method; multi-scale convolutional neural networks; antagonistic generation network

收稿日期: 2022-06-21; 修回日期: 2022-12-08

基金项目: 吉林省科技发展计划(2021050959RQ)

通信作者: 王辉东(1974—), 男, 硕士, 高级工程师, 主要从事电力设备状态评价与检测方面的研究; E-mail: 18244891@qq.com

作为电网运行的重要设备,变压器一旦发生故障将导致大面积的电力瘫痪,严重影响地区的生产生活。因此,变压器故障诊断已成为状态监测研究和应用的焦点<sup>[1-2]</sup>。

研究表明,电力变压器在发生热、电等故障时会引起绝缘油中相应气体的体积变化<sup>[3]</sup>,因此,大量的研究也是基于气相油色谱分析(dissolved gases analysis, DGA)<sup>[4]</sup>开展的。早期研究中主要采用三比值法<sup>[5]</sup>,该判别方法虽然为变压器故障划分提供了一定的依据,但存在主观经验性强、阈值附近分类效果不明显等缺陷<sup>[6]</sup>。随着计算机技术的快速发展,基于聚类分析、支持向量机等算法的变压器故障诊断策略得到了广泛应用,如:文献[7]提出了一种改进传统模糊聚类的变压器故障诊断模型;文献[8]通过引入灰云模型并采用白化权函数建立了实验数据与故障区间的隶属联系;文献[9]利用多尺度缩放法对20维变压器故障数据进行特征提取,然后输入到支持向量机中进行故障分类。虽然这些算法系统性强、人为干扰小,但也存在着许多问题。如在聚类分析中存在故障区间划分不确定<sup>[10]</sup>,指标权重分配仍需依靠专家经验<sup>[11]</sup>等问题;而支持向量机存在复杂的特征提取以及参数寻优过程,且常应用于二分类场景,对于变压器故障诊断的这种多分类问题处理起来相对麻烦<sup>[12]</sup>。

随着深度学习的发展,基于样本数据直接对问题进行分类的各种模型相继诞生,其中,卷积神经网络由于权重共享机制使得其参数量少,感受野机制使其提取的特征精度更高,因此得到更广泛的应用<sup>[13]</sup>。在变压器故障诊断领域也有不少学者引入过该模型,如:文献[14]利用卷积层提取DGA数据样本的特征,然后进一步输入至胶囊网络进行变压器故障分类;文献[15]设计了一个3层卷积的网络模型。然而由于目前大多数模型采用的都是二维卷积,故需对样本进行二维构造,但这导致样本原始结构受到了严重破坏。因此,为了保留样本的原始结构特征,采用一维卷积模型,同时为了增强模型的特征提取能力,设计2个多尺度卷积模块,最终设计一个含有多尺度卷积模块的多尺度卷积神经网络(multi-scale convolutional neural network, MCNN)诊断模型,用于变压

器的故障诊断。

## 1 MCNN模型的设计

### 1.1 一维卷积神经网络(1D-CNN)模型

传统的卷积神经网络(convolutional neural networks, CNN)由卷积层、汇聚层和全连接层交叉组合而成,其中卷积层主要由卷积核构成,作用相当于一个滤波器。卷积操作的数学表达式为

$$z_j^{l+1} = \sum_{i=1}^n W_{ij}^l a_i^l + b_j^l \quad (1)$$

式中, $z_j^{l+1}$ 为第 $l+1$ 层第 $j$ 个神经元的激活值; $a_i^l$ 为第 $l$ 层第 $i$ 个神经元的激活值; $W_{ij}^l$ 为第 $l+1$ 层第 $j$ 个神经元与第 $l$ 层第 $i$ 个神经元之间的权重; $b_j^l$ 为 $l$ 层所有神经元对 $l+1$ 层第 $j$ 个神经元的偏置。

汇聚层主要用于特征选择,通过池化选择特征并减少参数数量。池化操作目前较为常用的是最大池化,其在保留主要特征的同时增强了网络模型的非线性特点。最大池化的数学表达式为

$$p_i^{l+1}(j) = \max_{(j-1)w+1 \leq i \leq jw} \{q_i^l(t)\} \quad (2)$$

式中, $q_i^l(t)$ 为第 $l$ 层第 $i$ 个特征矢量中第 $t$ 个神经元的值; $w$ 为池化区域的宽度; $p_i^{l+1}(t)$ 为第 $l+1$ 层神经元对应的值。

全连接层的作用是将多次交替的卷积池化输出结果进行一维平铺,再进一步特征提取,最终连接softmax分类器对输入进行分类。softmax的数学表达式为

$$p(z_i) = \frac{e^{z_i}}{\sum_{k=1}^c e^{z_k}} \quad (3)$$

式中, $z_i$ 为输出层第 $i$ 个神经元的激活值; $c$ 为类别数; $p(z_i)$ 为输出层神经元的概率输出。

1D-CNN主要用来处理一维模型,模型的输入量、卷积核以及各层输出均为为一维向量的形式<sup>[16]</sup>。由于变压器故障样本为一维向量,因此,采用1D-CNN模型来进行分类识别较为合适。

### 1.2 多尺度卷积模块的设计

卷积核的尺度代表了其对于输入向量的感受野,在每层输入后面接入不同尺度的卷积核就可以获得该层输入的不同表征<sup>[17]</sup>。传统CNN模型

的卷积层一般采用一种尺度的卷积核,因此,每一时刻仅能得到输入的一种表征;多尺度卷积则利用不同大小的卷积核在同一时刻对输入层进行卷积操作,得到大小不同的表征从而丰富样本特征。由于DGA样本特征量少且特征间有着极强的非线性关联,如果直接输入到传统CNN模型中则需要设计非常深的结构才能实现良好的分类效果,这无疑将增加计算量,甚至容易导致模型过拟合<sup>[18]</sup>。

针对上述问题,本文在传统CNN的基础上,通过设计添加多尺度卷积层来精细化样本数据的特征表达,进而提高模型的识别效果。对于结构相似而故障类型不同的样本,当特征精度不断升级后这种相似性将大打折扣,经过多次卷积后特征的差异性也将越来越大<sup>[19]</sup>。为此,设计2个多尺度卷积层,具体结构如图1、2所示。

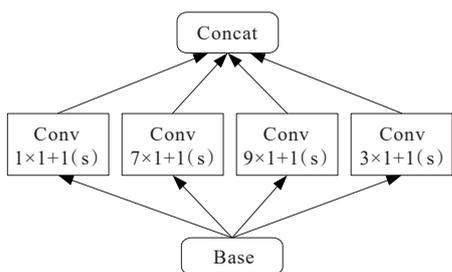


图1 多尺度卷积模块 a

Figure 1 Multiscale convolution module a

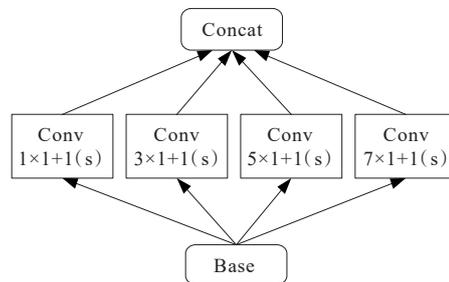


图2 多尺度卷积模块 b

Figure 2 Multiscale convolution module b

由图1、2可知,2个多尺度卷积模块都包含4个卷积分支,且为了保留上一层的信息参与下一层的特征提取,都采用了 $1\times 1$ 卷积分支,而其余卷积分支则设置了不同尺度的卷积核。这样,输入经过4个分支的特征提取得到4个不同的特征向量,将4个特征向量进行1维拼接作为模型后续的输出。

### 1.3 MCNN模型的搭建

结合1DCNN和多尺度卷积模块,构建变压器故障诊断的模型框架,共包含11层结构,其中前两层为连续的多尺度卷积层,后续为正常的卷积、池化和全连接层。为了减少输入数据在每次参数更新后的分布差异,以及为了加快模型训练的收敛速度,在中间层的每层输出后设置批量标准化处理(batch normalization, BN)<sup>[20]</sup>。经上述设置,所构建模型如图3所示,其相应的参数设置如表1所示。

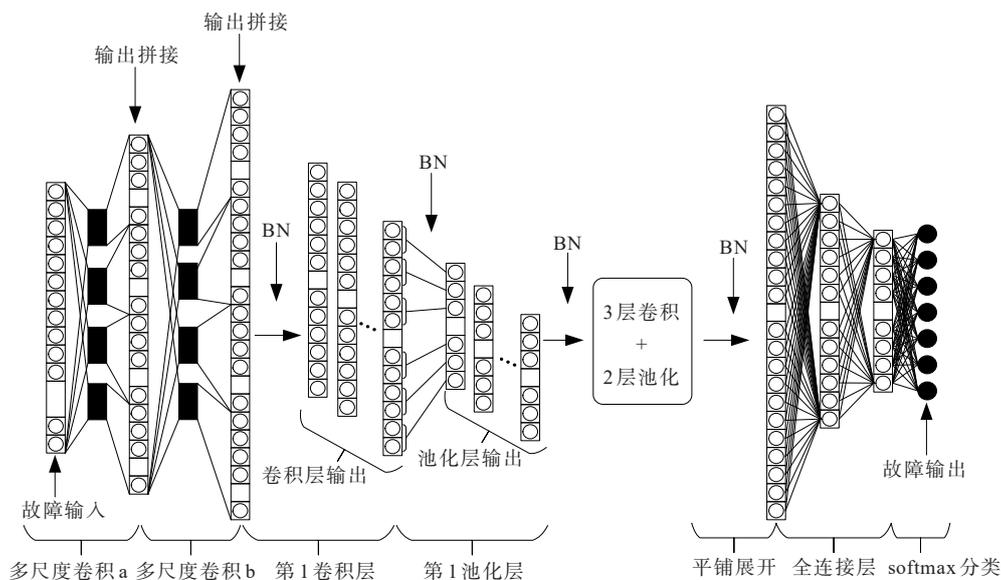


图3 MCNN模型结构

Figure 3 Structure diagram of the multi-scale 1DCNN convolution model

表 1 MCNN 模型参数设置

Table 1 Parameters of the multi-scale 1DCNN

类型	卷积核步长	卷积核个数	输出尺寸	类型	卷积核步长	卷积核个数	输出尺寸
输入	—	—	25×1	卷积层 1	9×1/1	8	313×8
多尺度卷积模块 a	1×1/1	1	84×1	池化层 1	3×1/2	8	105×8
	3×1/1	1		卷积层 2	7×1/1	16	99×16
	7×1/1	1		池化层 2	3×1/2	16	49×16
	9×1/1	1		卷积层 3	5×1/1	32	45×32
多尺度卷积模块 b	1×1/1	1	321×1	池化层 3	3×1/2	32	22×32
	3×1/1	1		卷积层 4	3×1/1	32	20×32
	5×1/1	1		全连接层	—	—	200×1
	7×1/1	1		softmax 输出	—	—	7×1

## 2 基于 MCNN 模型的故障诊断框架

### 2.1 基于比值法的样本特征增强方法研究

工程上一般通过采集 H<sub>2</sub>、CH<sub>4</sub>、C<sub>2</sub>H<sub>6</sub>、C<sub>2</sub>H<sub>4</sub> 和 C<sub>2</sub>H<sub>2</sub> 这 5 种气体对变压器故障类型进行判别。然而,因变压器型号、运行年限等原因使得直接采用的特征气体容易导致故障混叠。对此,中国电力研究者提出了“无编码比值法”,将 5 种气体含量的两两比值作为标准细化故障的分类界限,增强了变压器评判的普适性<sup>[21]</sup>。

另一方面,对于 1DCNN 模型,由于卷积核只在一个方向上滑动,因此当输入特征较少时会导致模型深度过浅,从而影响到模型的诊断准确率<sup>[22]</sup>。为了进一步提高模型的分类能力,文中基于 5 种基本气体并结合比值法将样本特征从 5 维增强至 25 维。扩展后的样本特征如表 2 所示,其中 T<sub>1</sub> 为气体总量, T<sub>2</sub> 为气体总烃。

表 2 重构样本特征的组分信息

Table 2 Component information of reconstructed samples

编号	输入特征	编号	输入特征	编号	输入特征
1	H <sub>2</sub>	10	C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>6</sub>	19	C <sub>2</sub> H <sub>4</sub> /T <sub>1</sub>
2	CH <sub>4</sub>	11	C <sub>2</sub> H <sub>6</sub> /C <sub>2</sub> H <sub>2</sub>	20	C <sub>2</sub> H <sub>6</sub> /T <sub>1</sub>
3	C <sub>2</sub> H <sub>2</sub>	12	C <sub>2</sub> H <sub>4</sub> /H <sub>2</sub>	21	H <sub>2</sub> /T <sub>1</sub>
4	C <sub>2</sub> H <sub>4</sub>	13	C <sub>2</sub> H <sub>6</sub> /C <sub>2</sub> H <sub>4</sub>	22	CH <sub>4</sub> /T <sub>2</sub>
5	C <sub>2</sub> H <sub>6</sub>	14	C <sub>2</sub> H <sub>6</sub> /H <sub>2</sub>	23	C <sub>2</sub> H <sub>2</sub> /T <sub>2</sub>
6	CH <sub>4</sub> /H <sub>2</sub>	15	C <sub>2</sub> H <sub>6</sub> /CH <sub>4</sub>	24	C <sub>2</sub> H <sub>2</sub> /T <sub>2</sub>
7	C <sub>2</sub> H <sub>2</sub> /CH <sub>4</sub>	16	H <sub>2</sub> /(T <sub>1</sub> +H <sub>2</sub> )	25	T <sub>2</sub> /T <sub>1</sub>
8	C <sub>2</sub> H <sub>2</sub> /H <sub>2</sub>	17	CH <sub>4</sub> /T <sub>1</sub>		
9	C <sub>2</sub> H <sub>2</sub> /CH <sub>4</sub>	18	C <sub>2</sub> H <sub>2</sub> /T <sub>1</sub>		

### 2.2 基于生成对抗网络的样本数量增强方法研究

由于变压器数据集故障样本数少且各类故障样本数差异较大,因此容易导致训练好的模型存在识别偏好。为了解决上述问题,文中采用生成对抗网络使数据集能够达到 MCNN 良好训练效果的要求。生成对抗网络由生成器 G 和判别器 D 共同组成<sup>[23]</sup>,其基本结构如图 4 所示;工作原理:生成器 G 和判别器 D 通过相互博弈调整对方参数,最终使两者达到纳什平衡。文中通过借助生成对抗网络使各故障类型的样本集得到增强,且分布均匀。

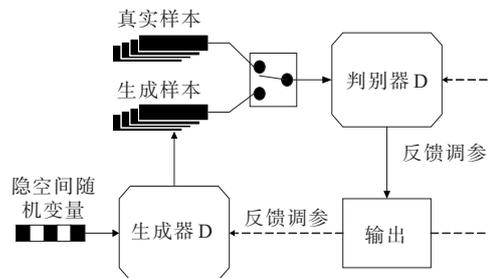


图 4 生成对抗网络工作示意

Figure 4 A schematic workflow of generative adversarial networks

### 2.3 设备状态编码

变压器故障总体上可分为热性和电性故障,根据放热与放电的状态等级可将变压器故障细划分为高温、中温、低温过热和高能、低能、局部放电这 6 种故障,为了方便计算损失函数,对变压器的运行状态编码,如表 3 所示。

表3 故障类型的编码信息

Table 3 Coding information of fault types

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

### 2.4 基于MCNN模型的故障诊断流程

MCNN模型的变压器故障诊断流程主要分为3个部分:数据集的准备与处理、模型的训练和测试,流程如图5所示,具体步骤如下:

- 1) 数据集预处理,包括样本重构、数据增强、划分训练集与测试集;
- 2) 设置模型的训练次数和学习率,初始化网络各层神经元的权重与偏置;
- 3) 输入数据并沿着网络前向传播;
- 4) 计算输出值与真实值的损失,并反向调整模型参数;
- 5) 当训练次数达到预设值时,观察损失函数值是否达到阈值,若达到则输出训练模型,否则返回步骤2),继续训练模型;
- 6) 将测试集输入训练模型,根据输出结果验证模型的可行性。

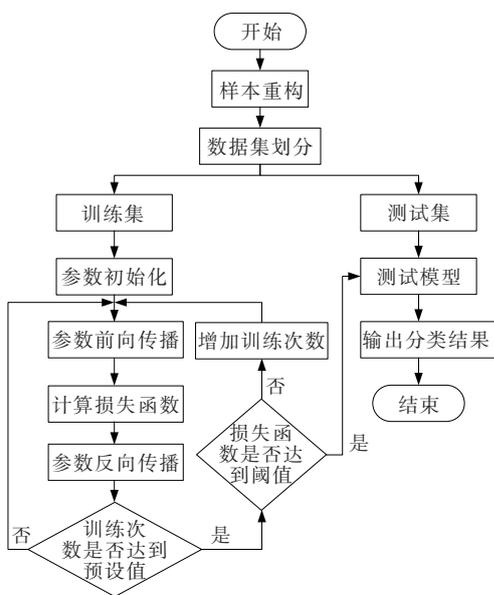


图5 基于MCNN模型的变压器故障诊断流程

Figure 5 Multi-scale 1DCNN transformer fault diagnosis flow chart

## 3 算例分析

### 3.1 数据集的准备与处理

为了测试多尺度卷积网络对变压器故障的诊断性能,采集了DGA数据样本563例。通过使用生成对抗网络增强,最终得到变压器运行状态数据1034例,其中,包括正常状态162例、高温过热146例、中温过热138例、低温过热154例、高能放电142例、低能放电154例以及局部放电138例。本文将数据集按照4:1的比例划分为训练集和测试集,具体分布如表4所示。

表4 变压器运行状态数据集分布情况

Table 4 Transformer operating status dataset

运行状态	训练集	测试集	运行状态	训练集	测试集
正常	130	32	高能放电	114	28
高温过热	117	29	低能放电	123	28
中温过热	110	28	局部放电	110	31
低温过热	123	31	共计	827	207

### 3.2 MCNN模型的训练与测试

采用Pytorch深度学习模型框架对文2中所设计的MCNN进行搭建,并在NVIDIA GeForce GTX 1050@4 GB的GPU下进行模型的训练和测试。首先,将训练样本输入到模型中;然后,设置迭代次数和批尺寸分别为55和15,设置初始学习率为0.0002,同时使用高斯随机数初始化模型每层神经元的权重和偏置;最后,以交叉熵作为损失函数并采用Adam优化器更新参数。

由于采用的模型共有11层结构,参数较多,因此具有一定的复杂度。为了训练出最佳的参数组合,防止模型过拟合,采用5折交叉验证对模型进行筛选,并选取5种模型中平均测试误差最小的作为最终模型。

为了将模型的训练过程可视化,提取模型训练阶段准确率以及损失函数随迭代次数的变化曲线,如图6所示,随着迭代次数的增加,模式识别准确率逐渐上升,损失值逐渐下降,当迭代次数达到30次后基本趋近平稳,此时模型训练良好。

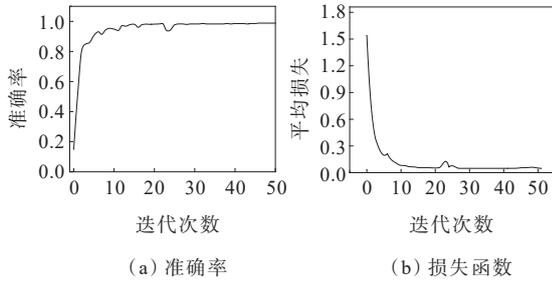


图 6 准确率、损失函数随迭代次数的变化曲线

Figure 6 Variation curve of accuracy rate, loss function with the number of iterations

为了验证模型的识别能力,采集测试集不同故障类型的测试结果,并整理模型对各故障类型识别情况,如表 5 所示。

表 5 模型测试结果  
Table 5 Model test results

故障类型	测试样本数	正确样本数	准确率/%
正常	32	30	95.24
高温过热	29	27	93.98
中温过热	28	26	93.33
低温过热	31	29	92.68
高能放电	28	26	93.33
低能放电	28	26	92.70
局部放电	31	28	91.76

## 4 结果分析与讨论

### 4.1 模型识别性能及泛化性能对比分析

为验证本模型在变压器故障诊断中的识别性能和泛化性能,将本模型与文献[8]中的 SSA-SVM 模型、文献[14]中的胶囊网络(capsule network)以及文献[15]中的 CNN 模型在不同测试集下进行实验对比。

首先,在原有数据集 A 的基础上,采集 3 种不同来源的数据集,分别为 IEC TC 10 数据集 B、文献[11]数据集 C 与文献[24]数据集 D;然后依次采用 4 种数据集的 1 种对上述 4 个模型进行训练,并采用剩余 3 个数据集进行测试;最后,计算测试结果的平均识别准确率,进而比较 4 种模型的识别性能和泛化性能。不同训练集下 4 种模型的识别情况如图 7 所示,可知本文所提模型在不同测试集下的识别率相对较高。因此,相较于现存模型,本文所建模型具有良好的泛化性能,适用于变压器故障诊断。

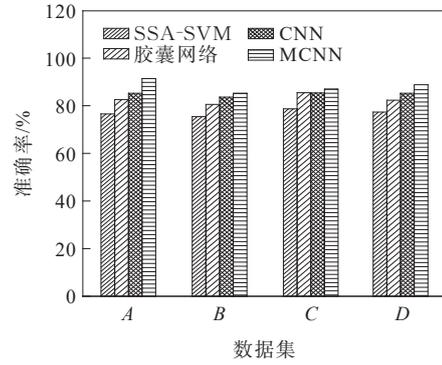


图 7 4 种模型的准确率识别情况

Figure 7 Recognition accuracy of the four models

### 4.2 基于比值法样本特征增强的影响分析

为了验证基于比值法样本特征重构的合理性,将原始样本、无编码比值法特征样本和重构特征后的样本分别作为数据集去训练和测试模型,并通过比较三者的 F1 分数值,最终确定样本特征重构对于模型性能改善的优劣影响。

F1 度量是统计学中常用来衡量二分类模型性能的一种指标,它同时兼顾了模型分类的准确率和召回率,其值越大意味着模型性能越好。由于本文所研究的问题为多分类问题,因此本部分采用宏观 F1 指标( $F_{1-macro}$ )对模型的分分类效果进行度量,表达式为

$$F_{1-macro} = 2 \times \frac{P_{macro} R_{macro}}{P_{macro} + R_{macro}} \quad (4)$$

其中, $P_{macro}$  为宏查准率, $P_{macro} = \frac{1}{n} \sum_{i=1}^n P_i$ , $R_{macro}$  为宏查全率, $R_{macro} = \frac{1}{n} \sum_{i=1}^n R_i$ , $P_i$ 、 $R_i$  分别为第  $i$  个混淆矩阵的查准率、查全率。

通过测试计算 3 种 MCNN 分类模型的查准率、查全率,最终计算得到 3 种模型的  $F_{1-macro}$ ,如表 6 所示,经特征重构后的样本数据集所训练出的模型  $F_{1-macro}$  相对较高,这也验证了特征重构增强了模型的分分类性能。

表 6 3 种 MCNN 模型的  $F_{1-macro}$

Table 6  $F_{1-macro}$  scores of three MCNN models

模型	$F_{1-macro}$
原始样本	0.636 7
无编码比值样本	0.792 6
特征重构样本	0.872 4

### 4.3 基于生成对抗网络样本增强的影响分析

为了证明生成对抗网络所生成模拟样本的有效性,本文采用主成分分析(principal component analysis,PCA)降维可视化的方法,将生成样本和真实样本数据分布情况进行对比。以低能放电和高温过热为例,通过选取样本主成分矩阵的前3个主成分,绘制真实和模拟样本集的分布对比散度,如图8所示,可知真实和模拟样本集样本分布偏差均较小,甚至出现重叠,证明模拟样本模拟效果良好。

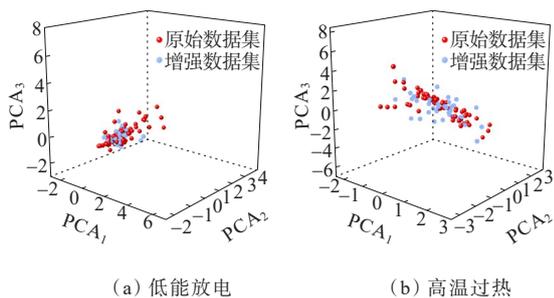


图8 低能放电、高温过热样本分布对比散度

Figure 8 Comparison divergence plot of low-energy discharge, high temperature overheated sample distribution

### 4.4 多尺度卷积模块尺度的影响分析

为研究多尺度卷积模块对于模型识别效果的影响,分别采用不同尺度的卷积核组合对模型的识别精度进行测试。首先,选取 $(1 \times 1, 3 \times 1, 5 \times 1, 7 \times 1, 9 \times 1, 11 \times 1, 15 \times 1)$ 7种不同尺度的卷积核,并使用 $C(*, *, \dots)$ 的形式表示不同尺度的卷积核组合,使用 $T(*)$ 表示训练时长(s);其次,将不同的卷积核组合作为一个多尺度卷积模块连接到1DCNN中,测得模型整体的准确度如图9所示。

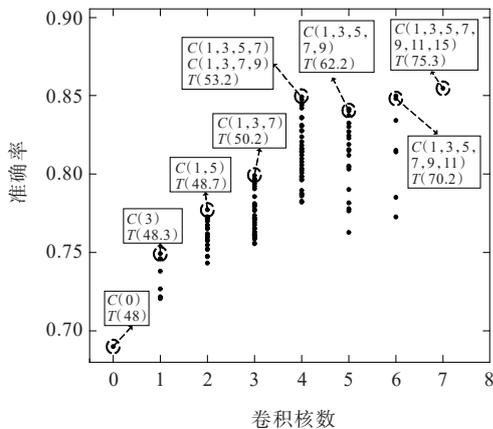


图9 不同多尺度卷积组模型识别情况

Figure 9 Model recognition of different multi-scale convolution groups

由图9可知,在采用0尺度卷积核的情况下,模型的准确率低于70%,随着卷积尺度数目的增加,模型的准确率也在逐渐增加,可达到约85%,这说明多尺度卷积能够更多地获取样本输入信息。然而,随着卷积尺度数目的增长,模型需要训练的时间也越来越长,当采用的多尺度卷积核数目超过4后,相对于训练时长,模型准确率的增长趋势不再明显。因此,为了提高模型的训练效率,决定每个多尺度卷积模块采用4种不同尺度的卷积核。进一步研究发现,当采用相同数目尺度的卷积核时,含有 $1 \times 1$ 尺度卷积核的组合准确率均为最高,表明 $1 \times 1$ 卷积有利于后续卷积继承原始样本信息,能进一步加强特征。

根据图9,当卷积核数为4时, $C(1,3,5,7)$ 和 $C(1,3,7,9)$ 都具有良好的识别效果。为了进一步探究哪种组合对于模型的改善效果最好,将2种组合分别作为一个卷积模块进行组合连接到1D-CNN中,构建4种不同的卷积模型。具体组合情况如表7所示。

表7 不同多尺度卷积组网络

Table 7 Different multi-scale convolutional group networks

模型	卷积组	模型	卷积组
1	$C(1,3,5,7)+$	3	$C(1,3,5,7)+$
	$C(1,3,5,7)$		$C(1,3,7,9)$
2	$C(1,3,7,9)+$	4	$C(1,3,7,9)+$
	$C(1,3,7,9)$		$C(1,3,5,7)$

为验证所采用的卷积组组合为最佳组合,分别对上述4种模型进行训练测试,训练过程如图10所示,可知4种组合中采用多尺度卷积组混和的模型准确率最高,即Model3和Model4,然而相较于Model3,Model4所采用的模型收敛速度最快;通过进一步比较Model1、Model2发现,Model2也比Model1收敛速度快但识别效果不如Model1。通过分析4种模型多尺度卷积组的前、后顺序发现,本文和Model2先采用的是大尺度卷积,而后使用的是小尺度卷积,而Model1和Model3恰好相反,因此,可以证明在建立多尺度卷积模型时,第1层多采用大尺度卷积有利于模型的收敛,而后采用小尺度卷积有利于模型准确率的提高。

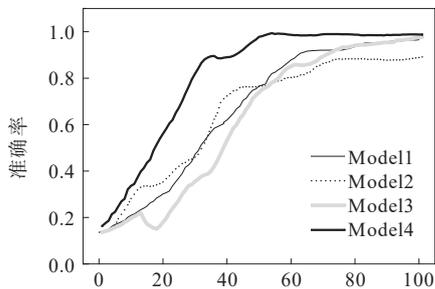


图10 4种模型的训练情况

Figure 10 Training of the four models

## 5 结语

为了提高变压器故障诊断的精度,本文提出了一种基于多尺度卷积模型的变压器故障诊断方法,通过与主流诊断算法进行对比以及相关分析论证,验证了该方法的有效性。

1) 相比于传统1D-CNN网络,MCNN在保留输入样本1维结构的同时,采用了不同尺度的卷积核同时卷积,提高了特征提取的精度,进一步增强了模型的分类能力;

2) 提出了基于比值法的样本特征扩充方法,细化了各故障的分类界限,提高了模型的分类精度;提出了基于生成对抗网络的样本数量增强方法,增加了模型的训练数量,解决了故障间样本量不平衡问题,避免了训练模型出现过拟合等问题;

3) 相比于SSA-SVM、CNN以及胶囊网络这些传统的变压器故障诊断算法,MCNN在不同场景的数据集下都表现了较高的识别能力,说明MCNN具有较强的识别性能和泛化性能。

### 参考文献:

[1] 党东升,张树永,葛鹏江,等.基于改进量子粒子群优化支持向量机的变压器故障诊断方法[J].电力科学与技术学报,2019,34(3):108-113.  
DANG Dongsheng,ZHANG Shuyong,GE Pengjiang,et al. Transformer fault diagnosis method based on support vector machine optimized by improved quantum-behaved particle swarm optimization[J]. Journal of Electric Power Science and Technology,2019,34(3):108-113.

[2] 马鑫,尚毅梓,胡昊,等.基于数据特征增强和残差收缩网络的变压器故障识别方法[J].电力系统自动化,2022,46(3):175-183.

MA Xin,SHANG Yizi,HU Hao,et al. Identification method of transformer fault based on data feature enhancement and residual shrinkage network[J]. Automation of Electric Power Systems,2022,46(3):175-183.

[3] 何宁辉,朱洪波,李秀广,等.基于贝叶斯网络和假设检验的变压器故障诊断[J].电力科学与技术学报,2021,36(6):20-27.  
HE Ninghui,ZHU Hongbo,LI Xiuguang,et al. Transformer fault diagnosis based on Bayesian network and hypothesis testing[J]. Journal of Electric Power Science and Technology,2021,36(6):20-27.

[4] 程宏波,刘嘉,康嘉斌,等.一种变压器健康状态的改进免疫识别方法[J].电力科学与技术学报,2018,33(2):141-147.  
CHENG Hongbo,LIU Jia,KANG Jiabin,et al. An improved immune recognition method for Transformer health status [J]. Journal of Electric Power Science and Technology, 2018,33(2):141-147.

[5] 谭俊明,张诗建.变压器故障诊断研究综述[J].机电工程技术,2021,50(10):12-14.  
TAN Junming, ZHANG Shijian. Review of transformer fault diagnosis method[J]. Mechanical & Electrical Engineering Technology,2021,50(10):12-14.

[6] 谢乐,衡熙丹,刘洋,等.基于线性判别分析和分步机器学习的变压器故障诊断[J].浙江大学学报(工学版),2020,54(11):2262-2272.  
XIE Le, HENG Xidan, LIU Yang, et al. Transformer fault diagnosis based on linear discriminant analysis and step-by-step machine learning[J]. Journal of Zhejiang University (Engineering Science),2020,54(11):2262-2272.

[7] 李恩文,王力农,宋斌,等.基于改进模糊聚类算法的变压器油色谱分析[J].电工技术学报,2018,33(19):4594-4602.  
LI Enwen,WANG Linong,SONG Bin,et al. Analysis of transformer oil chromatography based on improved fuzzy clustering algorithm[J]. Transactions of China Electrotechnical Society,2018,33(19):4594-4602.

[8] 朱保军,咸日常,范慧芳,等.WRSR与改进朴素贝叶斯融合的变压器故障诊断技术研究[J].电力系统保护与控制,2021,49(20):120-128.  
ZHU Baojun, XIAN Richang, FAN Huifang, et al. Transformer fault diagnosis technology based on the fusion of WRSR and improved naive Bayes[J]. Power System Protection and Control,2021,49(20):120-128.

[9] 谢国民,蔺晓雨.基于改进SSA优化MDS-SVM的变压器故障诊断方法[J].控制与决策,2023,38(2):459-467.  
XIE Guomin, LIN Xiaoyu. Transformer fault diagnosis method based on improved SSA optimized MDS-SVM[J]. Control and Decision,2023,38(2):459-467.

- [10] 刘云鹏,许自强,付浩川,等.采用最优云熵改进可拓云理论的变压器本体绝缘状态评估方法[J].高电压技术,2020,46(2):397-405.  
LIU Yunpeng, XU Ziqiang, FU Haochuan, et al. Insulation condition assessment method of power transformer based on improved extension cloud theory with optimal cloud entropy[J]. High Voltage Technology, 2020, 46(2): 397-405.
- [11] 李典阳,张育杰,冯健,等.变压器故障样本多维诊断及结果可信度分析[J].电工技术学报,2022,37(3):667-675.  
LI Dianyong, ZHANG Yujie, FENG Jian, et al. Multi-dimensional diagnosis of transformer fault sample and credibility analysis[J]. Transactions of China Electrotechnical Society, 2022, 37(3): 667-675.
- [12] 林凡勤,李明明,郭红.变压器故障诊断技术综述[J].计算机与现代化,2022(3):116-126.  
LIN Fanqin, LI Mingming, GUO Hong. Review on fault diagnosis technology of transform[J]. Computer and Modernization, 2022(3): 116-126.
- [13] ZHOU D X. Universality of deep convolutional neural networks[J]. Applied and Computational Harmonic Analysis, 2020, 48(2): 787-794.
- [14] 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):415-425.  
YANG Dechang, LIAO Wenlong, REN Xiang, et al. Fault diagnosis of transformer based on capsule network[J]. High Voltage Technology, 2021, 47(2): 415-425.
- [15] 李辉,张志攀,张中卫.基于卷积神经网络的变压器故障诊断[J].河南理工大学学报(自然科学版),2018,37(6):118-123.  
LI Hui, ZHANG Zhipan, ZHANG Zhongwei. Fault diagnosis of transformer based on convolutional neural network[J]. Journal of Henan Polytechnic University (Natural Science Edition), 2018, 37(6): 118-123.
- [16] 王伟,李开成,许立武,等.基于一维卷积神经网络多任务学习的电能质量扰动识别方法[J].电测与仪表,2022,59(3):18-25.  
WANG Wei, LI Kaicheng, XU Liwu, et al. Power quality disturbance recognition method based on multi-task learning and one-dimensional convolutional neural network[J]. Electrical Measurement & Instrumentation, 2022, 59(3): 18-25.
- [17] 卞景艺,刘秀丽,徐小力,等.基于多尺度深度卷积神经网络的故障诊断方法[J].振动与冲击,2021,40(18):204-211.  
BIAN Jingyi, LIU Xiuli, XU Xiaoli, et al. Fault diagnosis method based on a multi-scale deep convolutional neural network[J]. Journal of Vibration and Shock, 2021, 40(18): 204-211.
- [18] 林晓静,刘文,甘超飞,等.基于卷积神经网络与多维度电力大数据的信用评估系统[J].电测与仪表,2021,58(11):101-106.  
LIN Xiaojing, LIU Wen, GAN Chaofei, et al. Corporate credit assessment system based on convolutional neural network and multi-dimensional power big data[J]. Electrical Measurement & Instrumentation, 2021, 58(11): 101-106.
- [19] 李军,李明.改进多尺度卷积神经网络的人脸表情识别研究[J].重庆邮电大学学报(自然科学版),2022,34(2):201-207.  
LI Jun, LI Ming. Research on facial expression recognition based on improved multi-scale convolutional neural networks[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science), 2022, 34(2): 201-207.
- [20] KHARGHANIAN R, PEIRAVI A, MORADI F, et al. Pain detection using batch normalized discriminant restricted Boltzmann machine layers[J]. Journal of Visual Communication and Image Representation, 2021, 76: 103062
- [21] 王健一,李金忠,凌愨,等.新版电力行业标准《变压器油中溶解气体分析判断导则》解读[J].变压器,2014,51(12):49-53.  
WANG Jianyi, LI Jinzhong, LING Min, et al. Interpretation of the new electricity industry standard guide to the analysis and the diagnosis of gases dissolved in transformer oil[J]. Transformer, 2014, 51(12): 49-53.
- [22] 李平,胡根铭.基于改进神经网络与比值法融合的变压器故障诊断方法[J/OL].高电压技术:1-9[2022-08-05].  
<https://kns.cnki.net/kcms/detail/42.1239.TM.20220804.1702.035.html>.  
LI Ping, HU Genming. Transformer fault diagnosis method based on the fusion of improved neural network and ratio method[J/OL]. High Voltage Technology, 1-9[2022-08-05].  
<https://kns.cnki.net/kcms/detail/42.1239.TM.20220804.1702.035.html>.
- [23] 李雅欣,侯慧娟,胥明凯,等.基于策略梯度和生成式对抗网络的变压器油色谱案例扩充方法[J].电力自动化设备,2020,40(12):211-218.  
LI Yaxin, HOU Huijuan, XU Mingkai, et al. Oil chromatogram case generation method of transformer based on policy gradient and generative adversarial networks[J]. Electric Power Automation Equipment, 2020, 40(12): 211-218.
- [24] 苏小盟.基于神经网络和注意力机制的变压器状态预测和故障诊断研究[D].济南:山东大学,2021.  
SU Xiaomeng. Research on transformer state prediction and fault diagnosis based on neural network and attention mechanism[D]. Jinan: Shandong University, 2021.