

DOI:10.20033/j.1003-7241.(2026)02-0021-06

# 基于 MDF-BSRNet 的变压器声纹故障诊断方法

吴宁<sup>1</sup>, 王世旭<sup>1</sup>, 杨宏宇<sup>2</sup>, 王梓凡<sup>2</sup>, 李玉良<sup>3</sup>(1. 国网河南省电力公司超高压公司, 河南 郑州 450000; 2. 上海博英信息科技有限公司, 上海 200000;  
3. 沈阳工业大学机械工程学院, 辽宁 沈阳 110870)

**摘要:**针对单个传感器的变压器故障诊断方法不能充分提取特征信息,导致故障诊断精度较低的问题,提出了一种基于多传感器数据融合(multi-sensor data fusion, MDF)和双尺度残差网络(bi-scalar residual network, BSRNet)相结合的变压器故障诊断方法(MDF-BSRNet)。首先,构造了一种 MDF 方法,对多传感器采集的声纹信号进行融合并生成三维像素矩阵,从非线性数据的高维特征中捕获包含的低维特征,提高特征提取能力;其次,提出了一种 BSRNet 的智能故障诊断方法,通过学习三维矩阵中的深层和浅层特征,捕捉不同空间维度的故障特征,提高故障诊断能力;最后,通过实际采集的变压器声纹数据对所提方法进行试验验证,结果表明,所提方法故障识别准确率为 97.75%,优于其他深度学习方法,对多传感器声纹数据融合实际工程变压器故障诊断的研究具有重要意义。

**关键词:** 变压器;故障诊断;多传感器融合;双尺度残差网络;多传感器数据融合

**中图分类号:** TP277.3;TP212.9

**文献标志码:** A

**文章编号:** 1003-7241(2026)02-0021-06

## Fault diagnosis method of transformer voicing based on MDF-BSRNet

WU Ning<sup>1</sup>, WANG Shixu<sup>1</sup>, YANG Hongyu<sup>2</sup>, WANG Zifan<sup>2</sup>, LI Yulang<sup>3</sup>

(1. State Grid Henan Extra High Voltage Company, Zhengzhou 450000, Henan, China;

2. Shanghai Boying Information Technology Co., Ltd., Shanghai 200000, China;

3. School of Mechanical Engineering, Shenyang University of Technology, Shenyang 110870, Liaoning, China)

**Abstract:** Aiming at the problem that the transformer fault diagnosis method of a single sensor cannot fully extract the feature information, which leads to low fault diagnosis accuracy, this paper proposes a transformer fault diagnosis method MDF-BSRNet based on the combination of multi-sensor data fusion (MDF) and bi-scalar residual network (BSRNet). First, an MDF method is constructed to fuse the acoustic signals collected from multiple sensors and generate a 3D pixel matrix to capture the contained low-dimensional features from the high-dimensional features of the nonlinear data and improve the feature extraction capability. Second, an intelligent fault diagnosis method for BSRNet is proposed to improve the fault diagnosis capability by learning the deep and shallow features in the 3D matrix and capturing the fault features in different spatial dimensions. Finally, the effectiveness of the proposed method is verified by the actual collected data of transformer vowels. The results show that the fault identification accuracy of the proposed method is 97.75%, which is superior to other deep learning methods, and has important significance for the research of multi-sensor vowels data fusion in the fault diagnosis of transformers in practical engineering.

**Keywords:** transformer; fault diagnosis; multi-sensor data fusion; bi-scalar residual network; multi-sensor data fusion

近年来,基于深度学习的变压器故障诊断得到了广泛的研究<sup>[1-3]</sup>。通过深度学习网络能够实现从原始数据中自适应提取深度特征<sup>[4]</sup>,因此利用深度学习对变压器单传感器数据进行故障诊断得到了广泛的应用,并取得了积极的效果<sup>[5]</sup>。但这些方法采集的信号比较单一,难以保证变压器故障信息的完整性。

随着人工智能技术的发展,MDF的故障诊断方法受到广泛关注<sup>[6-7]</sup>。一般来说多传感器数据融合可细分为可分辨单元融合、互补特征级融合、属性融合和多源决策级融

合<sup>[8]</sup>。可分辨单元融合指将不同传感器的可分辨单元的数据直接融合,诊断的数据水平容易受到传感器的影响,导致诊断精度低于正常标准<sup>[9]</sup>。同时,多源决策级融合方法在学习网络中会占用大量的时间和内存。因此,上述两种融合方法不适合用于变压器的故障诊断。而特征级融合恰好能弥补多源决策级融合和可分辨单元融合的不足,能够有效识别故障。

特征级融合故障诊断主要由数据预处理和故障诊断两个部分组成<sup>[10]</sup>。数据预处理可以实现采集数据的降维

收稿日期:2023-12-26;录用日期:2024-05-28

基金项目:国家自然科学基金资助项目(51675350)

作者简介:吴宁(1979—),男,硕士,高级工程师,研究方向:超特高压变压器声纹故障诊断方面。

引用本文:吴宁,王世旭,杨宏宇,等.基于 MDF-BSRNet 的变压器声纹故障诊断方法[J].自动化技术与应用,2026,45(2):21-26.(WU Ning, WANG Shixu, YANG Hongyu, et al. Fault diagnosis method of transformer voicing based on MDF-BSRNet[J]. Techniques of Automation and Applications, 2026,45(2):21-26.)

和变换,融合得到低维特征数据。核主成分分析、等度量映射和线性判别分析是常用的数据降维方法<sup>[11]</sup>。但是,这些技术没有足够重视数据的局部结构特征,不能有效地处理变压器中的非线性数据。局部保持投影(locality preserving projection, LPP)是一种经典流形学习降维算法,它可以保留高维非线性数据的局部信息<sup>[12]</sup>,很好地解决了上述问题。将数据转换为易于识别的信号通常采用纹理灰度图像。由于纹理灰度图像技术直接对原始数据进行处理,减少了对先验知识的依赖,可以准确地反映了原始信号的特征<sup>[13]</sup>。因此,纹理灰度图像被越来越多的科研工作者用来进行信号处理和融合。文献[14]利用多个传感器的时域振动信号构建二维灰度矩形矩阵。然而,多传感器融合特征的提取具有一定的难度,在加深网络深度的同时,可能会导致严重的网络退化。

在上述分析的基础上,针对变压器传感器故障特征提取不完全和深度隐藏特征学习能力弱的问题,提出了一种基于MDF和BSRNet相结合的变压器故障诊断模型(MDF-BSRNet)。MDF方法实现高维非线性数据中嵌入的低维、高质量特征数据的提取和融合,BSRNet模型增强提取变压器融合数据和捕获远程空间故障相关信息的能力。通过实际采集的变压器声纹数据对所提方法进行有效性验证。

## 1 相关理论

### 1.1 LPP算法

LPP算法可以找到一个矩阵,将数据从高维流行空间投影到低维空间,这样可以保证数据样本在降维后仍然保持局部原始近邻关系<sup>[15]</sup>。

首先,构建了一个具有 $n$ 个顶点的近邻图,每个采样点都充当其中一个顶点。计算每个数据样本 $x_i$ 和所有其他样本之间的欧几里得距离。作为 $x_i$ 的最近相邻样本点,选择距离 $x_i$ 欧几里得距离最小的前 $k$ 个样本点。每个最近的邻居采样点通过一条边连接。然后,在最近近邻图中的每条边上放置一个权重。重量越大,样本越相似。权重矩阵 $W$ 由热核计算,可以表示为

$$W_{ij} = \begin{cases} e^{-\frac{\|x_i - x_j\|^2}{t}}, & x_i \approx x_j \\ 0, & \text{其他} \end{cases} \quad (1)$$

式中, $x_i$ 和 $x_j$ 是样本集的两个样本,参数 $t \in R$ 。

LPP方法通过迭代等式(1)的目标函数得到投影矩阵 $A$ ,从而实现数据从高维到低维的映射,并构造拉普拉斯矩阵。

$$\begin{cases} \operatorname{argmin}(A^T X V X^T A) \\ A^T X D X^T A \\ V = D - W = \sum_j W_{ij} - W \end{cases} \quad (2)$$

式中, $V$ 是拉普拉斯矩阵。

由式(2)中目标函数的解来解决广义特征方程的问题。

$$X V X^T a = \lambda X D X^T a \quad (3)$$

找到所有对应的特征值和特征向量,并根据特征值从

小到大排序。那么,可得到 $n$ 个特征值 $\lambda_0 < \lambda_1 < \dots < \lambda_{n-1}$ ,对应的特征向量为 $\{a_0, a_1, \dots, a_{n-1}\}$ 。取前 $m$ 个特征向量(即降维后的维数)形成投影矩阵 $A = [a_0, a_1, \dots, a_{m-1}]$ ,则降维后的数据可以表示为 $Y = A^T X$ 。

### 1.2 残差神经网络

残差神经网络(residual neural network, RNN)是一种可以缓解深度网络退化和降低训练困难程度的深度神经网络<sup>[16]</sup>。其核心思想是通过引入残差块使网络能够学习恒等映射,从而解决梯度消失的问题,其计算公式为

$$H(x) = F(x, \{w_i\}) + x \quad (4)$$

式中, $x$ 是残差块中的输入, $F(\cdot)$ 是残差中的映射函数, $w_i$ 是残差块的权重。残差模块的结构示意图如图1所示。




图1 残差块结构图

Fig. 1 Residual block structure diagram

## 2 模型设计

### 2.1 MDF模块

一种有效的MDF数据预处理方法可以获得更精确有用的高维非线性数据,具体步骤如下。

**步骤1** 使用多个传感器采集变压器不同位置的声音信号。由于这些传感器的采样频率不同,本文利用抗混叠滤波器对频率高的声音信号进行降采样处理,其经过处理的声纹信号具有相同的数据点。由多个传感器采集的声音信号可以表示为。

$$X_{init} = \{x_{ij}, i = 1, 2, \dots, \alpha; j = 1, 2, \dots, \beta\} \quad (5)$$

式中, $\alpha$ 为传感器个数, $\beta$ 为采样点个数。

**步骤2** 有效的特征提取和降维技术可以减少无用数据和信息冗余的影响。LPP算法在降低非线性数据的维度同时,还可以保持数据样本的局部流形结构。利用LPP降维后的数据可表示为

$$X_{lpp} = A^T X_{init} = \{x_{ij}, i = 1, 2, 3; j = 1, 2, \dots, \beta\} \quad (6)$$

**步骤3** 使用采样窗口从 $c$ 个通道的数据中依次截取长度为 $L = a^2$ 的信号段 $x^c$ 。本文采用重叠采样策略增加训练集的数量,并将传感器数据转换为灰度纹理图的二维矩阵,计算公式为

$$2DMatrix(a, a, c) = \frac{x^c - \min(x^c)}{\max(x^c) - \min(x^c)} \times 255 \quad (7)$$

式中, $a$ 表示上文求取的特征向量。

**步骤4** 将 $c$ 个二维矩阵沿通道编号合并为一个三维

像素矩阵,可表示为

$$\begin{aligned} 3\text{DMatrix}(\mathbf{a}, \mathbf{a}) &= (2\text{DMatrix}(\mathbf{a}, \mathbf{a}, 1), \dots, \\ &2\text{DMatrix}(\mathbf{a}, \mathbf{a}, 6)) \end{aligned} \quad (8)$$

### 2.2 BSRNet 模块

为增强变压器数据融合特征提取和捕捉故障相关信息的能力,本文提出 BSRNet,结构如图 2 所示。

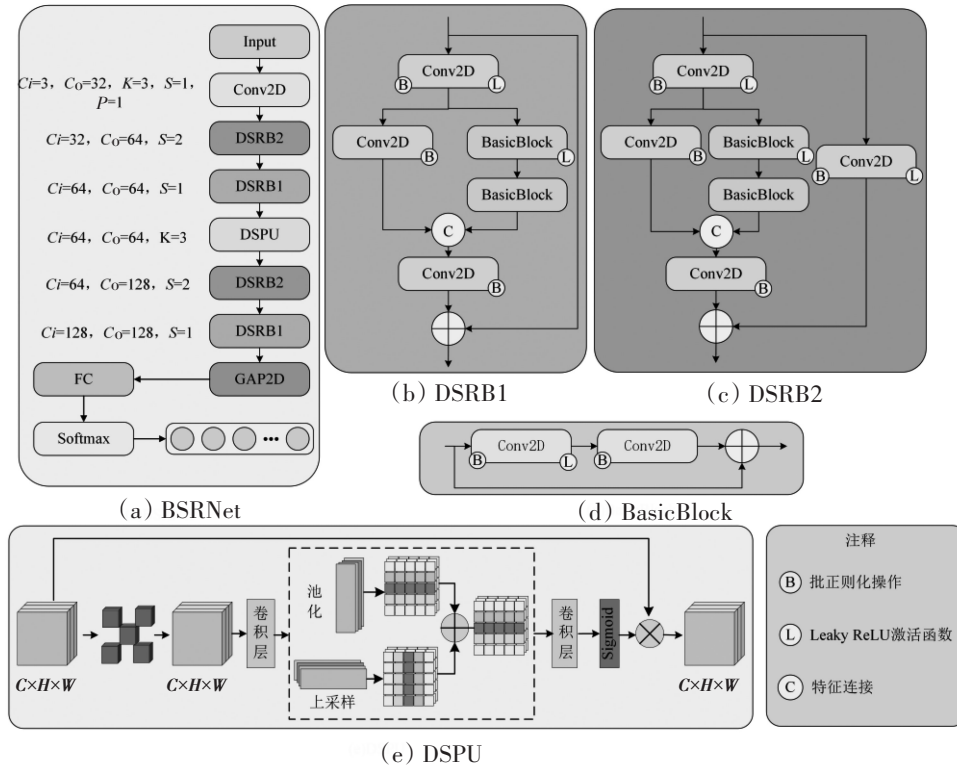


图 2 BSRNet 结构图

Fig. 2 Structure diagram of BSRNet

其中,  $C_i$  为输入通道数,  $C_o$  为输出通道数,  $K$  为卷积核大小,  $S$  为步幅大小,  $P$  为填充大小。

利用残差块结构的特性,本文所构造的双尺度残差块可以充分提取浅层特征和深层特征,同时保留局部特征信息和全局特征信息。首先,对特征层进行卷积处理,卷积核为  $1 \times 1$ 。该操作对特征进行降维并增加了通道的数量。然后将其分为两部分,其中一部分特征输入到两个基本块中,捕捉特征之间的深层关系,增强特征提取能力。

为了加快模型训练速度,避免过拟合问题,本文利用 Leaky ReLU 激活函数来替代原来的 ReLU 函数,计算公式为

$$\text{Leaky ReLU}(x) = \max(x, px) = \begin{cases} x, & x \geq 0 \\ px, & x < 0 \end{cases} \quad (9)$$

式中,  $x$  为输入,  $p$  为泄露因子,一般情况下泄露因子选择 0.01 表现最佳。

为了进一步获取不同传感器所采集到的相关特征信息,提出了深度条纹池化单元 (deep-depth strip pooling unit, DSPU),以提高捕获远程空间依赖和利用通道间依赖的能力,其结构如图 2(e) 所示。首先,利用扩展深度卷积提取不同通道中的故障相关特征,深度卷积核的大小设为  $3 \times 3$ ,然后,水平和垂直条纹池化操作能够捕获融合信号中不同空间维度的远程故障相关信息。条纹池化减少

了距离较远的位置之间的连接,并且可以大大减少彼此之间的计算量。

首先使用三维像素矩阵作为 BSRNet 的输入,通过第一层卷积初始提取相关特征。其次,通过 DSRB 模块提取深层特征和浅层特征,增强特征提取能力。然后, DSPU 模块捕获输入数据中不同空间维度的故障相关信息。利用 GAP 层进行特征降维,实现特征的平移不变性。最后,通过全连接层将聚类特征转换为一维向量。分类任务根据通过 Softmax 函数实现分类任务概率的计算。

### 2.3 故障诊断流程

本文提出了一种基于 MDF-BSRNet 的变压器故障诊断方法。整个流程框架如图 3 所示。

1) 首先,对变压器采集的多传感器数据进行预处理。多通道时域数据经 LPP 降维后转换成三维像素矩阵,便于深度卷积网络处理。

2) 然后,对生成的三维像素矩阵进行标记和随机洗牌。总数据集按比例分为训练集、验证集和测试集。利用训练集和验证集对 MDF-BSRNet 的参数进行训练和优化。

3) 最后,将训练好的模型应用于变压器故障诊断。通过测试集对该方法的综合诊断性能进行了验证和分析。

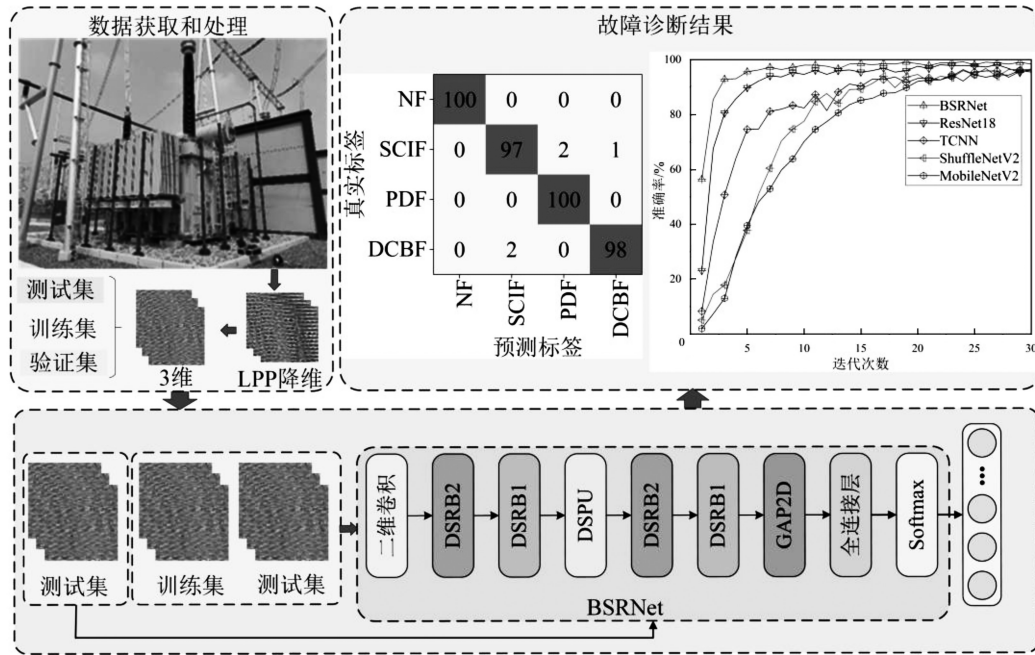


图3 故障诊断流程

Fig. 3 Fault diagnosis process

### 3 试验验证

#### 3.1 试验设置

为了验证 MDF-BSRNet 模型对变压器不同故障情况下声纹信号的识别能力,利用采集仪采集郑州某电厂变压器的6通道声纹信号。其中,传感器在变压器前后分别布置2个,左右分别布置1个,具体情况如图4所示,采样频率为10 000 Hz,单次采样时间为1 s。所用传感器的灵敏度为57 mV/Pa。



图4 多通道变压器信号采集

Fig. 4 Signal acquisition of multi-channel transformer

根据所采集变压器声纹信号数据,划分为4种故障类别,分别为正常、短路冲击、局部放电和直流偏置,其标签分别为0、1、2、3,具体标签情况如表1所示。

表1 变压器故障类型标签和缩写

Tab. 1 Transformer fault type labels and abbreviations

故障类别	标签	缩写
正常	0	NF
短路冲击	1	SCIF
局部放电	2	PDF
直流偏置	3	DCBF

表2 变压器数据集划分

Tab. 2 Transformer dataset division

故障类别	训练集	验证集	测试集
0	250	150	100
1	250	150	100
2	250	150	100
3	250	150	100

本文所采用数据集的样本总数为2 000,每类500个样本,按照5:3:2的比例划分为训练集、验证集和测试集,具体情况如表2所示。

#### 3.2 性能测试与结果分析

##### 3.2.1 模型性能测试与结果分析

为了验证本文所提方法的有效性,保持数据集不变的情况下,将 BSRNet 模型与 TCNN<sup>[17]</sup>、ResNet18<sup>[18]</sup>、ShuffleNetV2<sup>[19]</sup> 和 MobileNetV2<sup>[20]</sup> 4种方法进行比较,其训练各方法迭代结果如图5、6所示。




图5 各方法训练准确率

Fig. 5 Training accuracy rates of each method




图6 各方法训练损失率

Fig. 6 Training loss rates of each method

由图5、6可以看出,BSRNet模型的收敛速度最快。在第8次训练后,曲线趋于稳定。ResNet18模型诊断性能较次于BSRNet模型,曲线上升平稳。TCNN、ShuffleNetV2和MobileNetV2 3种模型的训练曲线接近,收敛速度较慢,整体诊断精度较低,损失率较高,表明此3种模型故障提取特征能力较弱。但是,TCNN模型的诊断性能略好于ShuffleNetV2和MobileNetV2两种模型。综上所述,BSRNet模型在精度、损失率和收敛速度上明显优于其他四种模型。

为了进一步测试BSRNet模型的性能,将上文数据集测试集输入到BSRNet模型中,其变压器故障诊断准确率和耗时情况如表3所示。

表3 各方法故障诊断准确率和耗时情况

Tab. 3 Shows the accuracy and time consumption of fault diagnosis for each method

方法	准确率/%	耗时/s
TCNN	94.29	722
ResNet18	97.28	1 328
ShuffleNetV2	90.15	700
MobileNetV2	94.45	596
BSRNet	97.75	604

由表3可以看出,BSRNet模型的故障准确率均高于其他几种模型。但BSRNet模型的诊断耗时与MobileNetV2相比相差不大,与其他3种模型相比具有较好的优势,进一步证明了本文所提的BSRNet模型的优越性。

### 3.2.2 MDF模块性能测试与结果分析

为了验证MDF模块的有效性,本文将MDF模块连接BSRNet、ResNet18、ShuffleNetV2、TCNN和MobileNetV2 5种模型,组成MDF-BSRNet、MDF-ResNet18、MDF-TCNN、MDF-ShuffleNetV2和MDF-MobileNetV2 5种模型,并将以上5种方法与单通道传感器的BSRNet(Signal-BSRNet)进行对比,其故障诊断混淆矩阵如图7所示。

由表3和图7可以看出,添加了MDF模型后BSRNet、ResNet18、ShuffleNetV2、TCNN和MobileNetV2的故障诊断

准确率都有所提高。其中,MDF-ShuffleNetV2故障诊断准确率的提升率最高,提高了2.1%;但MDF-BSRNet模型故障诊断精度仍是最高,达到了98.75%,相较于BSRNet模型提高了1%,充分证明了本文提出的MDF模块的有效性。

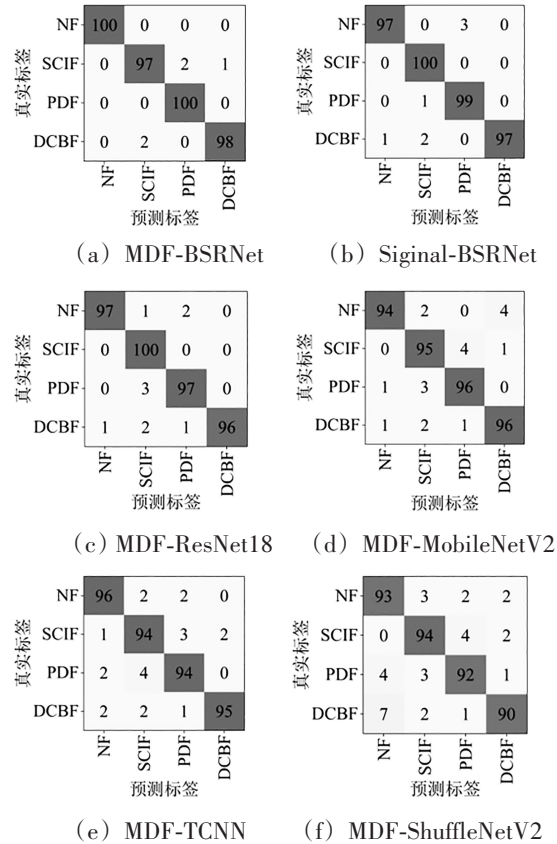


图7 各方法故障诊断混淆矩阵

Fig. 7 Confusion matrix for fault diagnosis of each method

### 3.2.3 MDF-BSRNet模型性能评价

为了进一步评价所提MDF-BSRNet方法的性能,本文引入采用召回率和 $F_1$ -Score对MDF-BSRNet、MDF-ResNet18、MDF-TCNN、MDF-ShuffleNetV2和MDF-MobileNetV2 5种方法进行评价,其结果如图8所示。




图8 各方法故障诊断结果对比

Fig. 8 Comparison of fault diagnosis results of each method  
由图8可看出,本文所提MDF-BSRNet模型的召

回率和  $F_1$ -Score 都是最大。其中,与居于第 2 位的 MDF-ResNet18 模型相比,MDF-BSRNet 模型召回率高了 0.95%,  $F_1$ -Score 高了 0.98%;与最差的 MDF-ShuffleNetV2 模型相比,MDF-BSRNet 模型召回率和  $F_1$ -Score 分别高了 6.75% 和 6.5%  $F_1$ -Score,进一步证明了 MDF-BSRNet 模型的优越性。

## 4 结论

针对单传感器电力变压器故障诊断方法存在的特征提取不足、诊断准确率低等问题,本文提出了基于 MDF-BSRNet 的变压器故障诊断方法,并利用在郑州某电厂采集的数据验证了 MDF-BSRNet 模型的有效性和优越性,主要结论如下。

1) 本文构造了一种 MDF 方法。该方法能够融合多个传感器数据,并提取非线性数据中多维特征所包含的低维高质量特征数据,为故障诊断提供了一种可靠的数据预处理方法。

2) 本文提出了基于 BSRNet 的变压器故障诊断方法。一方面,利用多个残差块提取三维矩阵的深浅双层特征,从而增强特征表达能力;另一方面,DSPU 可以获取变压器声纹信号远程空间维度的故障信息。与传统的残差网络相比,BSRNet 方法能够提高网络特征提取能力,加快网络训练速度。

3) 通过采集的变压器声纹数据验证了 MDF-BSRNet 的故障诊断性能。结果表明,MDF-BSRNet 方法能有效区分变压器各故障类型的特征,具有很强的特征提取能力。与其他深度学习方法与 Siginal-BSRNet 相比,本文所提 MDF-BSRNet 的变压器故障诊断方法在准确性和耗时方面均为最优。

## 参考文献

[1] 郭晓菡,牛鑫,李勇杰,等. 基于贝叶斯算法的电力变压器全寿命周期故障概率预测[J]. 电子设计工程, 2023, 31(13):32-35, 40.  
 [2] 田振宇. 基于负序电信号的变压器绕组匝间故障检测系统[J]. 电子设计工程, 2023, 31(11):111-115.  
 [3] 王雨虹,王志中,付华,等. 多策略改进麻雀算法与 BiLSTM 的变压器故障诊断研究[J]. 仪器仪表学报, 2022, 43(3):87-97.  
 [4] 赵莉华,张振东,张建功,等. 运行工况波动下基于振动信号的变压器故障诊断方法[J]. 高电压技术, 2020, 46(11):1925-1933.  
 [5] 王广庭,李阳海,杨涛,等. 基于振动信号分析的变压器故障诊断

研究进展[J]. 噪声与振动控制, 2016, 36(5):150-154,179.  
 [6] 李楠,马宏忠,段大卫,等. 基于多传感器融合声纹特征图谱的变压器铁芯松动故障诊断方法[J]. 振动与冲击, 2023, 42(15):129-137, 198.  
 [7] ZHANG Chaolong, HE Yigang, DU Bolun, et al. Future generation computer systems[J]. Issue, 2020(108):533-545.  
 [8] TRAN M Q, LIU M K, ELSISI M. Effective multi-sensor data fusion for chatter detection in milling process[J]. ISA Transactions, 2022(125):514-527.  
 [9] WANG Jianxin, Zhao zhishan, ZHU Jun, et al. Improved support vector machine for voiceprint diagnosis of typical faults in power transformers[J]. Machines, 2023(11): 539.  
 [10] YI LINGZHI, LONG JIAO, HUANG JIANXIONG, et al. Fault diagnosis of oil-immersed transformer based on MGTO-BSCN[J]. Journal of Intelligent & Fuzzy Systems, 2023, 44(4):6021-6034.  
 [11] LU Wanjie, SHI Chun, FU Hua, et al. A power transformer fault diagnosis method based on improved sand cat swarm optimization algorithm and bidirectional gated recurrent unit[J]. Electronics, 2023(12):672.  
 [12] HUANG Ziqing, TANG Zhenjun, ZHANG Xianquan, et al. Perceptual image hashing with locality preserving projection for copy detection[J]. IEEE Transactions on Dependable and Secure Computing, 2023, 20(1):463-477.  
 [13] JARDIM Sandra, ANTONIO Joao, MORA. Carlos Graphical image region extraction with k-means clustering and watershed[J]. Journal of Imaging, 2022, 8(6): 163.  
 [14] WANG Jiaying, WANG Dazhi, WANG Sihan, et al. Fault diagnosis of bearings based on multi-sensor information fusion and 2D convolutional neural network[J]. IEEE Access, 2021(9):23717.  
 [15] HUR Jee-Sic, LEE Hyeong-Geun, KANG Shinjin, et al. 3D face reconstruction from a single image using a combined pca-lpp method[J]. Computers Materials & Continua, 2023, 74(3): 6213-6227.  
 [16] NISA S Q, ISMAIL A R. Dual U-net with resnet encoder for segmentation of medical images[J]. International Journal of Advanced Computer Science and Applications, 2022, 13(12):537-542.  
 [17] XU G, LIU M, JIANG Z, et al. Online fault diagnosis method based on transfer convolutional neural networks[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 69(2):509-520.  
 [18] PENG F, MU L, FANG C. Fault diagnosis of shipboard medium-voltage alternating current power system with fault recording data-driven SE-Res Net18-1 model[J]. IEEE Transactions on Electrical and Electronic Engineering, 2024, 19(3): 403-413.  
 [19] NING S, WANG Y, CAI W, et al. Research on intelligent fault diagnosis of rolling bearing based on improved shufflenetV2-LSTM[J]. Journal of Sensors, 2022, 2022(1):8522206.  
 [20] XUE T, WANG H, WU D. MobileNetV2 combined with fast spectral kurtosis analysis for bearing fault diagnosis[J]. Electronics, 2022, 11(19): 3176.