

DOI: 10.19783/j.cnki.pspc.241186

基于声纹脊线化和元学习的变压器故障诊断方法

曲朝阳^{1,2}, 刘谊豪¹, 曲楠³, 姜涛¹, 徐晓宇¹

(1. 东北电力大学, 吉林 吉林 132012; 2. 吉林省电力大数据智能处理工程技术研究中心, 吉林 吉林 132012;
3. 国网南京供电公司, 江苏 南京 210000)

摘要: 针对变压器声纹检测中信号易受干扰且足量样本获取困难的问题, 提出一种融合声纹脊线化与元学习的变压器声纹诊断方法。首先, 基于脊线化特征处理, 对优化后的变压器声纹时频谱图进行物理特征筛选与形态特征压缩。然后, 搭建选择性编码器(selective encoder, SE)加深时频与形态表征的关联度, 提升模型收敛速度。最后, 构造元学习网络评估变压器状态, 并引入基于 OD-Reptile 的一阶梯度更新策略, 通过内外循环优化机制增强参数泛化性, 从而实现少样本、信息干扰条件下的高精度声纹诊断。相较于 R-WDCNN、LSTM、CNN 等传统深度学习信号诊断方法, 该方法在低样本、高噪声环境下(SNR 为-12 dB), 收敛轮数减少 10 轮以上。同时, 准确率分别提高 6.35%, 12.1% 和 16.93%。实验结果显示, 所提方法在准确性、抗噪性、鲁棒性以及泛化性方面均有显著提升。
关键词: 声纹; 小样本; 脊线化; 时频谱图; 选择性编码; 元学习; 故障诊断

Transformer fault diagnosis method based on acoustic ridging and meta-learning

QU Zhaoyang^{1,2}, LIU Yihao¹, QU Nan³, JIANG Tao¹, XU Xiaoyu¹

(1. Northeast Electric Power University, Jilin 132012, China; 2. Jilin Electric Power Big Data Intelligent Processing Engineering Technology Research Center, Jilin 132012, China; 3. State Grid Nanjing Power Supply Company, Nanjing 210000, China)

Abstract: To address the challenges in transformer voiceprint detection, namely, signal susceptibility to interference and difficulty in obtaining sufficient training samples, a transformer voiceprint fault diagnosis method that integrates acoustic pattern ridging and meta-learning is proposed. First, based on the ridge feature processing, the optimized transformer voice pattern time spectrum is selected for physical feature screening and morphological feature compression. A selective encoder (SE) is then constructed to enhance the correlation between time-frequency and morphological representations, improving model convergence speed. Finally, a meta-learning network is designed for transformer state evaluation. An OD-Reptile-based first-order gradient update strategy is introduced, and an inner-outer loop optimization mechanism is used to enhance parameter generalization. This enables accurate voiceprint diagnosis under limited sample and noisy conditions. Compared with traditional deep learning methods, such as R-WDCNN, LSTM, and CNN, the proposed method reduces the number of convergence iterations by more than 10 rounds in low-sample, high-noise environments (SNR is -12 dB). Accuracy is improved by 6.35%, 12.1%, and 16.93%, respectively. Experimental results demonstrate significant improvements in accuracy, noise immunity, robustness, and generalization.

This work is supported by the National Natural Science Foundation of China (No. 52377081).

Key words: voiceprint; small samples; ridging; time-frequency spectrograms; selective encoding; meta-learning; fault diagnosis

0 引言

大型电力变压器不仅是电网中的高价值资产, 更是保障电力供应稳定性的关键。为了确保其稳定

运行, 定期的设备维护成为了必不可少的工作^[1-2]。随着电力行业的发展, 诊断策略已由周期性停电检查转向连续的不停电检测。然而, 传统方法如油色谱分析^[3-5]和电气参数分析^[6-7]等在实时监控和非接触检测方面仍存在局限性, 难以在响应速度、成本效益和操作便捷性上满足现代工业的高标准要求。

基金项目: 国家自然科学基金项目资助(52377081)

文献[8]提出的基于声学诊断的专家系统验证了声纹技术在负载开关变压器故障诊断中的应用价值。声纹检测技术无须直接接触变压器或进行复杂的化学分析,即可实时监测其运行状态,为变压器故障诊断提供了一种更为高效和可靠的手段。传统的声纹检测分为声纹特征提取和识别网络两个阶段。在声纹特征提取阶段,许多研究者采用梅尔频率倒谱系数(Mel-frequency cepstral coefficients, MFCC)、线性预测倒谱系数(linear predictive cepstral coefficients, LPCC)等基于语音信号的特征提取方法来进行变压器声纹故障诊断,由于信号特性的差异性和环境因素的多样性,这种方法无法充分捕捉变压器完整的故障特征。因此,许多研究者基于变压器声纹特点进行改进,文献[9]采用梅尔-格拉姆角差场(Mel-scaled Gramian angular difference field, Mel-GADF)时频谱图进行声纹特征提取。该方法通过改进传统 Mel 时频谱图,解决了低频缺失问题,提高了特征提取的完整性。上述方法结合了变压器振动特性和常用音频特征处理方式,但未充分考虑信噪比的影响,导致声纹信号中的冗余特征与判别特征被赋予相同权重^[10]。此外,仅依赖变压器声纹特性提取特征可能遗漏关键信息,单一特征驱动模型架构则可能因结构简化而削弱其收敛性与鲁棒性。

在声纹识别阶段,研究人员已研究了通过使用深度学习模型,如卷积神经网络(convolutional neural network, CNN)、长短期记忆网络(long short-term memory, LSTM)和门控循环单元(gated recurrent unit, GRU)来进行故障识别的方法。文献[11]提出了一种基于 LSTM 神经网络的诊断方法,通过提取梅尔频率倒谱系数特征,并利用 LSTM 网络对变压器正常、过载和放电状态下的声音进行分类。文献[12]提出了一种结合快速增量式支持向量数据描述(fast incremental support vector data description, FISVDD)和门控循环单元的变压器声纹识别方法, FISVDD 用于初步分类, GRU 用于进一步分类,提高了识别的准确性和鲁棒性。然而,变压器的声纹故障获取难度大,少量样本下的模型过拟合现象频发。文献[13]采用迁移学习解决小样本训练问题,但其效果依赖于源任务与目标任务的相似性。当任务差异较大时,该方法易导致负迁移,同时高计算成本限制了其在资源受限环境下的应用。而元学习因其快速的适应性、卓越的泛化能力和高效的资源利用,在小样本信号处理上体现出显著的优势。因此本文以元学习为基础,提出基于声纹脊线化和元学习^[14-15]的变压器故障诊断方法(transformer fault diagnosis method based on voiceprint ridge and meta-learning,

TVRM)。该方法采用时频谱图特征法进行特征优化,并采用脊线化处理对特征进行压缩提取,利用选择性编码器增强对经过脊线化处理的时频谱图特征的适应性。为解决模型训练样本不足的问题,采用基于元学习 OD-Reptile 的一阶梯度更新算法,其中“OD”表示基于不同工况的任务内样本分配(within-task samples assignment based on operational conditions, WTSAOS)和基于动态度量函数(dynamic feature distance, DFD)的梯度冲突衰减(gradient conflict attenuation based on dynamic similarity, GCADS),相较于传统方法,TVRM 模型在复杂环境中处理小样本数据时显示出显著的准确性、鲁棒性和泛化能力。

1 TVRM 算法

为了能够在强干扰和小样本的条件下快速、准确地识别变压器机械故障,本文提出了一种声纹脊线化和元学习的变压器故障诊断方法。

本节将首先介绍 TVRM 算法包含的总体流程,随后逐步深入分析该算法中的核心技术要点。总体流程如图 1 所示。

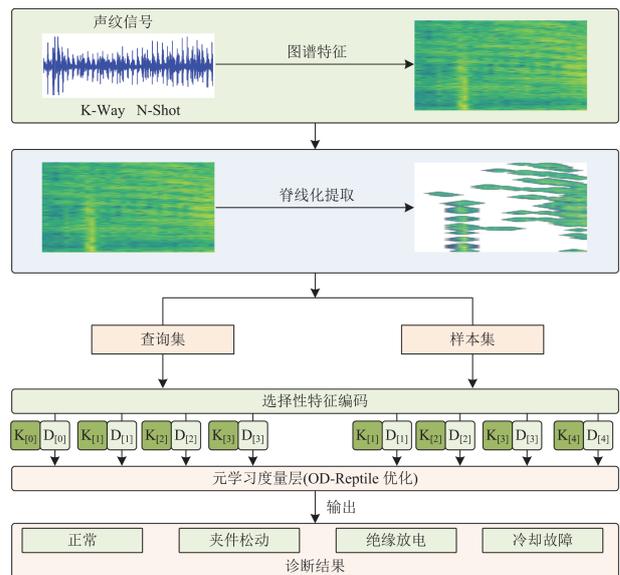


图 1 TVRM 算法总体流程图

Fig. 1 Overall flowchart of the TVRM algorithm

1) 声纹特征脊线化。为挖掘信号特征脊线化信息,首先提出时频谱图特征算法,时频谱图的特征提取由改进短时傅里叶变换(short-time Fourier transform, STFT)、中心频率、局部峰度因子和同步提取算子 4 部分构成,旨在实现高信噪比且增强化的谱图特征。最后采用带通滤波器并进行 K 均值聚类提取脊线,确保通过物理精选和形态压缩的方式提高特征质量。

2) 选择性特征编码。由于度量元学习方法高度

依赖输入特征的分度和表征能力, 高质量特征编码至关重要。模型以脊线压缩后的特征图作为输入, 并引入选择性编码器(selective encoder, SE), 通过动态调整卷积核尺寸, 精准地捕捉不同时频区域和形态的特征信息, 从而适应不同时频区域内的基频与谐波。同时相应地调整膨胀率^[16]以适应形态特征的变化, 并对其进行加权以增强特征关联性。

3) 元学习诊断。将特征编码后的特征向量输入到元学习框架中的度量网络中, 引入 OD-Reptile 算法进行内外循环的梯度优化。在内循环中, 选用 WTSAOC 方法, 通过对支持集样本进行合理的工况场景划分, 确保模型在任务内能够更加高效地学习具有代表性的特征。在外循环中, 采用 GCADS 方法, 通过优化与查询集特征之间的相似度量进行全局梯度更新, 进一步提升模型在多任务环境下的泛化能力。元学习相关概念如表 1 所示。

表 1 元学习相关概念

Table 1 Meta-learning related concepts

概念	解释
支持集和查询集	支持集为模型提供用于学习的示例, 而查询集则用于测试模型的泛化能力, 检验其对新样本的识别效果
K-Way	模型通过接触 K 个类别中的 N 个示例, 学习快速
N-Shot	适应新类别的能力
度量	利用先前任务的知识, 通过学习任务间的相似性度量
元学习	来提升模型在小样本环境中的泛化能力的方法

2 变压器声纹特征优化与脊线化

为了深入分析和挖掘变压器声纹信号中的关键信息, 需要对声纹信号进行有效的时频特征提取。传统的特征提取方法, 如梅尔频率倒谱系数和线性预测倒谱系数, 尽管能够有效地捕捉信号的某些频谱特性, 但在处理复杂或非平稳信号时, 这些技术往往无法保留信号中的非线性成分。此外, 依赖于傅里叶变换和小波变换的时频分析方法^[17]在处理信号中的低能量成分和窗函数导致的信号泄漏时, 常常会产生大量冗余信息, 对关键特征的提取产生负面影响。为应对这些挑战, 本文提出了一种基于脊线化处理的声纹特征压缩算法, 其流程如图 2 所示, 旨在根据声纹信号物理特性与形态特性进行特征提取优化, 减少噪声冗余, 从而更准确地捕获和表征声纹特征。本文将介绍变压器声纹时频谱图特征提取流程和特征的脊线化处理方法。

2.1 时频谱图特征算法

时频谱图是声纹信号特征提取的重要工具。本文提出了一种改进的短时傅里叶变换方法, 结合多功能自适应窗函数、优化同步提取算子, 以实现时

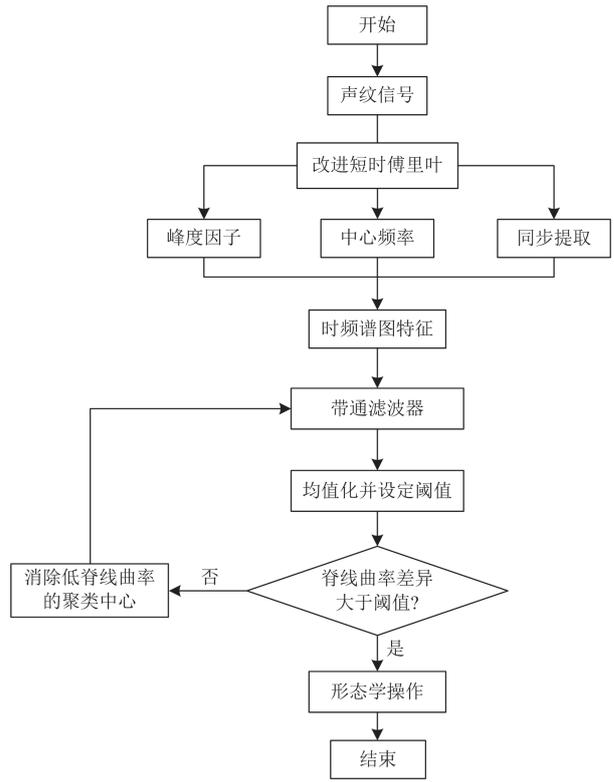


图 2 脊线化特征处理流程

Fig. 2 Ridged feature processing flow

信号在不同时间点的频率特性进行精确分析。通过这种方式生成的时频谱图优化信号特征提取的精度和信噪比。

1) 改进的短时傅里叶变换

时频谱图常用于声纹特征提取, 通过引入改进短时傅里叶变换, 结合多功能自适应窗口, 对信号在不同时间点的频率特性进行精确分析, 表示为

$$S_i = \int_{-\infty}^{\infty} s(\tau) w_a e^{-j2\pi f\tau} d\tau \quad (1)$$

式中: $s(\tau)$ 表示原始信号函数; τ 表示在当前时段 t 窗函数的中心位置; w_a 表示多尺度自适应窗函数; f 表示此刻的频率; $e^{-j2\pi f\tau}$ 表示短时傅里叶变换的核函数。自适应窗函数结合了小波变换的思想, 通过缩放和平移母小波函数, 在多个尺度上对信号进行分析, 表示为

$$w_a = \frac{1}{k\sqrt{2\pi}} e^{-\frac{f^2(t-\tau)^2}{2k^2}} \quad (2)$$

式中: k 表示动态调整尺度调节因子, 以优化时频谱图信噪比, 如式(3)所示。

$$k = \frac{M}{C} \quad (3)$$

式中: M 表示最高层小波系数子带区间中小波熵最

大区间里的小波系数的中值； C 表示归一化因子，根据数据集统计得到，此处采用小波熵最大区间的小波系数的中位数。

2) 中心频率计算

为进一步优化时频分析，通过计算信号在每个时刻 t 处的中心频率 $\omega_0(t)$ 来捕捉信号的主频率成分。中心频率 ω_0 的计算表达式为

$$\omega_0(t) = \frac{\int C_f \cdot |p|^2 d\omega}{\int |p|^2 d\omega} \quad (4)$$

式中： C_f 表示频率重心； p 表示此时间和频率点上的功率谱强度，以分析典型频率特点提取时频脊线，并识别信号中潜在的异常频率行为。

3) 局部峰度因子

为了提高对声纹信号中特征性尖锐变化和突变特性的敏感度，引入局部峰度因子捕捉放大信号的局部尖锐变化和突变，特别是在信号中出现异常或高频扰动时，显著提高在高信噪比中特征提取的精度。局部峰度因子 $K(t, f)$ 定义为

$$K(t, f) = \frac{E[S_i - \tilde{\mu}^4]}{(E[S_i - \tilde{\mu}^2])^2} \quad (5)$$

式中： E 表示期望值计算，使得在特征化处理中有效保留信号的瞬时功率谱特征，增强对声纹信号中异常事件和短时高频变化的响应； $\tilde{\mu}$ 表示时频点的平滑均值，用于考虑更大范围内的时间和频率邻域。

4) 同步提取算子

为从声纹信号中优化脊线时频特征分辨率，并减少信号变换中的能量发散、混叠和端点效应。使用同步提取算子结合局部峰度因子的调整，优化信号的特征提取过程。同步提取算子 T 表示为

$$T = S_i \cdot K(t, f) - \tilde{S}(t, f - \omega_0(t)) \quad (6)$$

式中： \tilde{S} 表示频率偏移后的信号强度，用于消除与目标特征无关的分量。时频谱图特征 S_{feature} 如式(7)所示。

$$S_{\text{feature}}(t, f) = \int_{-\infty}^{\infty} T e^{-j2\pi f\tau} d\tau \quad (7)$$

通过改进 STFT、自适应窗函数、局部峰度因子和同步提取算子，旨在提取信号中最具辨识度的时频谱图特征。

2.2 变压器声纹特征脊线化

2.1 节中提取的变压器声纹时频谱图特征能较好地描述时频域的特征变化，但其中的冗余特征数据量仍然很多，包括但不限于

1) 非主要信号成分：包括那些能量较低或不稳定的频率成分，不具代表性或与主要信号无关。

2) 信号泄漏：由于窗函数和变换的性质，信号部分能量在时频表示中“泄漏”到其他频率。

现有对变压器声纹特征的研究表明^[18]，变压器的声纹频率主要集中在0~4000 Hz，变压器声纹在运行时具有 50 Hz 的基础频率，所采集的各类故障声纹信号在频谱上均表现出以该基频为中心的相似能量分布特性。基于此，本文设计中心频率为 50 Hz 的声纹脊线化带通滤波器，通过调整其参数来增强声纹频率特征选择，随后使用均值聚类方法进行特征形态压缩。

2.2.1 脊线带通滤波器频率选择

带通滤波器是一种基于物理特性进行时频特征脊线化处理的有效手段^[19]，通过保留特定频率范围内的信号成分，突出关键时频结构，显著提升脊线特征的清晰度与定位准确性。脊线带通滤波器 $H_m(n)$ 如式(8)所示。

$$\begin{cases} H_m(n) = \frac{1}{2}[1 - \cos(2\pi \cdot D)] \\ D = \frac{\max(0, \min(n - f(m-1), f(m+1) - n))}{f(m+1) - f(m-1)} \end{cases} \quad (8)$$

式中： m 表示滤波器的索引； n 表示信号频谱的离散点位置，其采用汉宁窗形式实现； 2π 表示滤波器的周期特性； $f(m)$ 表示中心频率； $f(m-1)$ 表示低频截止点； $f(m+1)$ 表示高频截止点。

2.2.2 K 均值形态压缩

为有效提取时频谱图中的脊线特征，本研究采用 K 均值聚类方法进行特征压缩。首先，将频率筛选后的时频谱图特征输入 K 均值模型，聚为 10 类，通过聚类中心对图像不同区域的形态特征进行归类。随后，针对每个聚类中心所代表的图像区域，计算其边缘曲率的变化程度，并按曲率差异大小进行排序。选取曲率差异排名第二的聚类中心作为二值化阈值，生成掩码图，仅保留曲率差异排名前两位的聚类区域，以突出脊线的显著形态特征。

设 $C = \{c_1, c_2, \dots, c_{10}\}$ 为聚类中心集合， V 为量化后的图像，则量化过程可以表示为

$$V(x, y) = C_{\min_{c_i \in C} \|\Delta\kappa_{\text{avg}} - C_i\|} \quad (9)$$

式中： C_{\min} 表示寻找使得脊线曲率差异最小的聚类中心； C_i 表示更精确地衡量脊线特征之间的几何差异，本研究采用离散形式的曲率差异计算方法。设 $\kappa_1(s_i)$ 和 $\kappa_2(s_i)$ 分别为两条脊线在离散点 s_i 处的曲率，则脊线曲率差异 $\Delta\kappa_{\text{avg}}$ 可表示为

$$\Delta\kappa_{\text{avg}} = \frac{1}{n_s} \sum_{i=1}^{n_s} |\kappa_1(s_i) - \kappa_2(s_i)| \quad (10)$$

式中： n_s 表示离散点的数量，二元阈值处理后的图像 $B(x, y)$ 可以表示为

$$B(x, y) = \begin{cases} 1, & \text{if } V(x, y) \geq \varphi \\ 0, & \text{otherwise} \end{cases} \quad (11)$$

式中: φ 表示阈值, 选取聚类中心脊线曲率差异第二高的值(假设聚类中心按升序排列); 在完成聚类分组后, 采用形态学操作进一步优化聚类结果, 包括: 通过闭运算连接相邻区域并填补孔隙, 结合膨胀操作扩展目标区域, 以增强特征表达能力, 同时进行孔洞填充以消除遗漏区域, 从而提升聚类结果的完整性与可靠性。

3 声纹识别元学习网络

元学习作为机器学习中的一个重要分支, 主要解决模型如何快速适应新任务的问题。在数据稀缺的情况下, 元学习能够通过少量样本高效学习, 这对于快速适应、知识迁移^[20]和提升泛化能力尤为关键。在基于声纹的故障诊断中, 脊线化处理后的声纹特征蕴含丰富的时频信息, 具有高度的区分性。为了充分挖掘这些特征并加速模型的收敛, 本文选择基于度量的元学习方法, 首先阐述优化的元学习编码器, 然后介绍用于小样本参数更新的 OD-Reptile 优化算法。

3.1 选择性编码器

SE 模块网络架构如图 3 所示。SE 模块针对脊柱柱化频谱图特征进行设计, 包含 6 个卷积层, 分布在不同的层级, 分为 Split、Fuse、Select 三个阶段, 以实现高效且精确的特征编码。在 Split 阶段, 采用基于膨胀卷积的多尺度策略, 使用 3、5、7 三种卷

积核和相应的膨胀率, 通过扩大感受野有效捕捉信号的形态特征。随后, 通过最大池化和平均池化在时间和频率尺度上压缩特征维度, 保留关键信息。接着, 在 Fuse 阶段, 网络末端采用自适应池化技术统一输出特征尺寸, 将这些多尺度特征进行融合, 利用自注意力机制确保信息的全面整合。使得物理和形态特征能够协同发挥作用。最后的 Select 阶段, 通过通道注意力机制自适应分配不同尺度的卷积核和膨胀率的权重, 在不同频率和形态特征之间实现最优的特征组合。SE 架构参数如表 2 所示。

表 2 SE 架构参数

Table 2 SE architecture parameters

组件层	参数			输入	输出
	卷积核	膨胀率	步长		
Conv1	3/5/7	2	1	1×1024	64×1016
MaxPoolong1	2×2	—	2	64×1016	64×508
AvgPooling2	2×2	—	2	64×508	64×254
Conv2	3/5/7	2	1	64×254	64×246
MaxPoolong1	2×2	—	2	64×246	64×123
AvgPooling2	2×2	—	2	64×123	64×61
Conv3	3/5/7	2	1	64×61	64×53
Adaptive Pooling1	—	—	—	64×53	64×26
Conv4	3/5/7	3	1	1×1024	64×1004
MaxPoolong1	2×2	—	2	64×1004	64×502
AvgPooling2	2×2	—	2	64×502	64×251
Conv5	3/5/7	3	1	64×251	64×241
Adaptive Pooling2	—	—	—	64×241	64×26

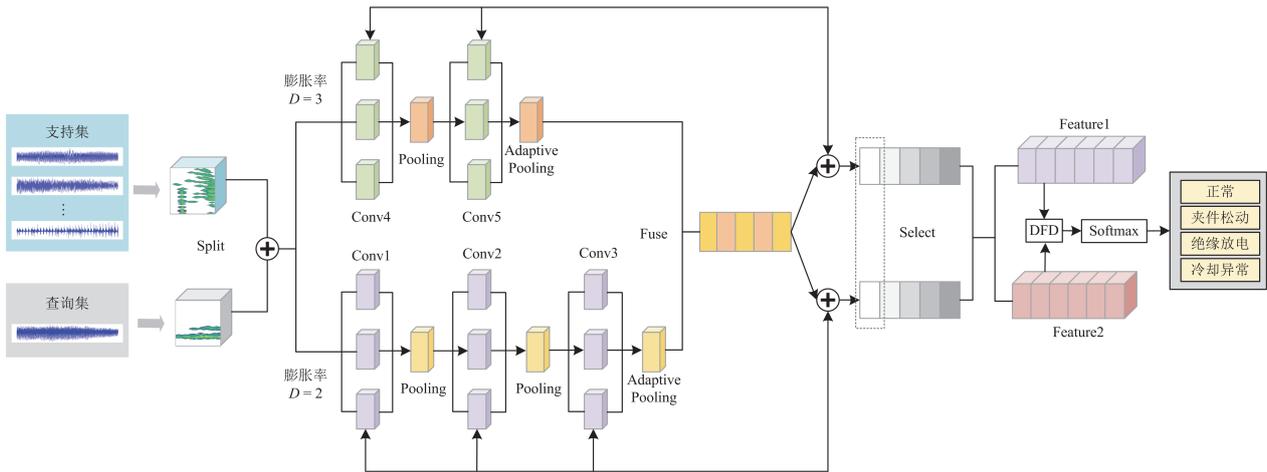


图 3 SE 网络架构

Fig. 3 SE network architecture

3.2 OD-Reptile 梯度更新算法

针对少样本条件下的故障诊断问题, 提出了一种基于 OD-Reptile 的元学习梯度更新方法。该方法

基于 Reptile 元学习框架, 采用了内外循环优化策略, 通过跨任务学习实现了模型的快速泛化和适应能力, 其中包括 WTSOS(O)和 GCADS(D)两个核

心模块。

1) 基于不同工况的任务内样本分配

在变压器声纹信号诊断中,不同工况下存在显著的时频特征差异性。为增强模型在复杂工况条件下的泛化能力,本文根据工况属性(如负载、温度变化)对支持集样本进行划分,并构建多个子任务。在内循环训练过程中,动态选取来自不同运行场景的子集进行训练,通过梯度下降不断更新模型参数。其更新公式为

$$\phi_{i+1}^{(i)} = \phi_i^{(i)} - \alpha \nabla_{\phi} \mathcal{L}(\phi_i^{(i)}; \mathcal{D}_{\text{support}}^{(i)}) \quad (12)$$

式中: $\phi_i^{(i)}$ 表示当前第 i 个工况下的模型参数; α 表示学习率; \mathcal{L} 表示在该工况下的交叉熵损失函数; $\mathcal{D}_{\text{support}}^{(i)}$ 表示与该工况对应的支持集样本。通过对每个工况样本的梯度更新,模型能够针对不同工况的特征进行学习,同时确保各工况的特征有效融合,增强模型在多样化工况下的学习能力。这一过程优化了任务内的样本分配,提升了模型在真实工况下对故障的泛化能力。

2) 基于动态相似度的梯度冲突衰减

在 OD-Reptile 的外循环中,模型通过综合多个任务的梯度信息来优化全局初始化参数,从而提升模型在不同任务中的泛化能力。在多任务学习的场景下,任务间的特征相似性直接影响模型的学习效果。为此,引入了动态特征距离函数,使用方差比率作为选择欧氏距离^[21]或余弦相似度^[22]的依据,优化特征表示差异敏感度,如式(13)所示。

$$d(x, y) = \begin{cases} \sqrt{\sum_{i=1}^l (a_i - b_i)^2} & Q \leq \zeta \\ \sum_{i=1}^l a_i b_i & \\ \sqrt{\sum_{i=1}^l a_i^2} \sqrt{\sum_{i=1}^l b_i^2} & Q > \zeta \end{cases} \quad (13)$$

式中: $d(x, y)$ 表示第 x 个样本与第 y 个样本间的动态特征距离; l 表示特征向量的维度; a_i 和 b_i 分别为样本 x 、 y 的特征向量在第 i 个维度上的取值; ζ 表示判断方差比率 Q 是否显著的一个预设值。

接下来,在外循环更新过程中,通过 DFD 对任务间梯度进行动态调整,以缓解任务间的梯度冲突。具体更新公式为

$$\theta' = \theta - \beta \sum_i \nabla_{\theta} \mathcal{L}_i^{\text{DFD}}(\theta_i; \mathcal{D}_{\text{query}}) \quad (14)$$

式中: θ 、 θ' 表示更新前、后的全局初始化参数; β 表示外循环的学习率; $\mathcal{L}_i^{\text{DFD}}$ 表示第 i 个任务使用动态度量函数计算得到的损失; ∇_{θ} 表示相对于全局

参数 θ 的梯度,用于执行外循环梯度更新; θ_i 表示第 i 个任务经过内循环训练后从全局参数 θ 更新得到的局部参数; $\mathcal{D}_{\text{query}}$ 表示查询集中的样本数据。

在每个任务的内循环训练完成后,外循环通过分析各任务的损失梯度特性,采用融合优化策略更新全局模型参数。该方法不仅整合了多任务特征信息,还通过协调梯度方向缓解优化冲突,确保全局优化的连贯性与收敛性。针对多任务环境,该方法动态平衡任务差异性与共享性,挖掘任务间潜在相关性,从而提供了一种能稳定提升泛化能力的通用参数初始化方案。理论上,这种策略可同时提高模型训练效率和优化质量。

4 算例分析

4.1 数据集构建

本研究收集的声纹数据来源于浙江芝堰变电站及山东某变电站共 7 所变电站的 36 台 500 kV 变压器,涵盖了夹件松动(loose fixture, LF)、绝缘放电(insulation discharge, ID)、冷却异常(cooling anomaly, CA)3 种标准故障类型。此外,为确保数据的广泛适用性,样本不仅涵盖了单一故障状态下的声纹,还涵盖了不同故障程度以及变压器在各种运行工况下的多样性^[23]。数据采集时考虑了诸如负载变化(如过载和正常负载)、环境条件(变电站南北差异下的高温和低温)、电网状态(如谐波污染和正常电压)等多种工况。

所有声纹数据均通过相同型号的高精度声学设备进行采集。根据奈奎斯特采样定理,为了完整捕捉变压器声纹信号的频率范围(0~4000 Hz),采样率至少设置为 8000 Hz。本研究选择 16 000 Hz 采样率,以提高信号保真度并避免频谱混叠,确保关键特征的完整保存。采集到的故障声纹信号被进一步分割为每段包含 2000 个点的片段。为确保信号中的关键特征得以最大限度地保留,分割过程中采用了 50% 的重叠采样策略,从而有效减少了重要信息的丢失。每种故障类型的样本数量如表 3 所示,其中包括不同工况下的样本数量分布情况。通过这种样本分布设计,确保模型在训练和验证阶段能够涵盖多种实际运行条件,提高了模型在复杂工况下的适应性和泛化能力。

4.2 评价指标

为了验证 TVRM 算法的性能,将准确率 A 、精确率 P 、召回率 R 、F1 指数作为评价指标,如式(15)~式(18)所示。此外,本文引入收敛轮数作为评估模型训练效率的补充指标,收敛轮数表示模型在

表 3 声纹数据集构成

Table 3 Voiceprint dataset composition

样本类型	工况	声纹类别	数量
正常	正常	主变正常(N)	105
		主变+雷声	82
		主变+鸟鸣	92
		主变+人声	83
		主变+汽笛	91
异常	过载/正常	夹件松动(LF)	85/75
	谐波/正常	绝缘放电(ID)	74/89
	高温/正常	冷却异常(CA)	76/80

优化过程中, 损失函数达到稳定或满足停止条件所经历的迭代次数。

准确率衡量模型预测正确的样本比例, 反映整体分类性能。

$$A = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \quad (15)$$

精确率表示模型预测为正例时实际为正例的比例, 衡量模型的准确性。

$$P = \frac{T_p}{T_p + F_p} \quad (16)$$

召回率衡量在所有实际正例样本中模型成功识别的比例, 反映模型的敏感性。

$$R = \frac{T_p}{T_p + F_n} \quad (17)$$

F_1 表示精确率和召回率的调和平均数, 综合了模型的准确性和敏感性。

$$F_1 = 2 \times \frac{P \times R}{P + R} \quad (18)$$

式中: T_p 表示真正例; T_n 表示真反例; F_p 表示假正例; F_n 表示假反例; P 表示模型参数数量, 包括所有可训练的权重和偏置, 直接影响模型的复杂度和学习能力。

同时为了验证信号优化后的保真率, 在此处引入峰值信噪比(peak signal-to-noise ratio, PSNR)和结构相似性指数(structural similarity index measure, SSIM)作为评判指标, 如式(19)和式(20)所示。

$$M_{\text{PSNR}} = 10 \cdot \lg \left(\frac{L^2}{M_{\text{SE}}} \right) \quad (19)$$

$$M_{\text{SSIM}} = \frac{(2\mu_x \mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (20)$$

式中: L 表示信号的最大可能值; M_{SE} 表示均方误差; μ_x 、 μ_y 分别表示原始图像 x 和重建图像 y 在局部窗口内的均值; σ_x 、 σ_y 分别表示 x 和 y 在局

部窗口内的标准差; σ_{xy} 表示协方差; C_1 、 C_2 为常数; M_{PSNR} 表示衡量去噪信号与原始信号的误差, 数值越高表示保真度越好(20 dB 以上为良好); M_{SSIM} 表示衡量谱图在结构、亮度与对比度 3 个方面与原图的相似性, 越接近 1, 保真度越高。

4.3 性能分析

当前主流的声纹诊断技术都是对声纹样本进行基于语音信号的特征提取, 或者采用 MFCC 进行谱图转换后, 采用深度学习中的卷积神经网络对信号进行故障分析, 由于变压器声纹信号与轴承振动信号在特征处理和故障诊断方面具有一定相似性, 本文综合分析了在小样本振动信号处理中表现优异的 R-WDCNN^[24]算法, 并将其与基于 MFCC 的常规声纹处理算法(MFCC-CNN, MFCC-LSTM)进行了性能对比, 高噪声环境选择信噪比(signal-to-noise ratio)SNR 为-12 dB 的雷雨天气, 反映了实际运行中可能面临的极端噪声环境, 以评估模型的抗干扰能力。训练阶段通过从多种工况中随机抽取样本, 采用了 4-Way 50-Shot 配置进行训练。表 4 介绍了 3 种对比算法模型。

表 4 不同算法模型相关概念

Table 4 Concepts related to different algorithmic models

模型名称	参数量	每轮时间/s	介绍
R-WDCNN	87 040	0.98	基于 WDCNN 引入残差块和自适应批归一化, 增强深层特征提取和抗噪能力
MFCC-LSTM	136 700	0.37	提取声纹信号的倒谱系数特征, 利用 LSTM 处理时间序列信号分类
MFCC-CNN	155 200	1.15	将音频信号转换为 MFCC 谱图特征, 基一维卷积进行分类

图 4 直观地展示了各模型在训练集上的准确率和训练损失随着训练轮数增加的变化趋势。可以看出, 各模型在训练过程中呈现出不同的性能差异。此外, 图 5 展示了不同模型在测试集上对各类故障的诊断结果, 以混淆矩阵形式呈现。TVRM 模型不仅在准确率方面表现出明显的上升趋势, 而且在较少训练轮数内实现快速收敛, 同时其训练损失也显著低于其他对比模型, 表现出更优的收敛性能和学习效率。

TVRM 模型在分类性能上展现出明显的优势, 其对不同类别故障的诊断准确率均保持较高水平, 误分类率极低。表 5 汇总了不同算法模型在准确率、精确率、召回率以及 F1 指数 4 个关键指标上的对

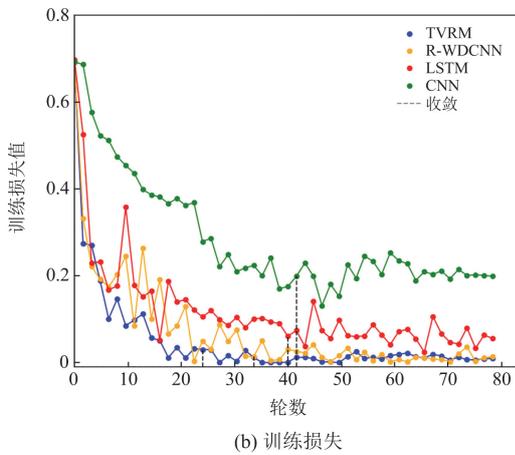
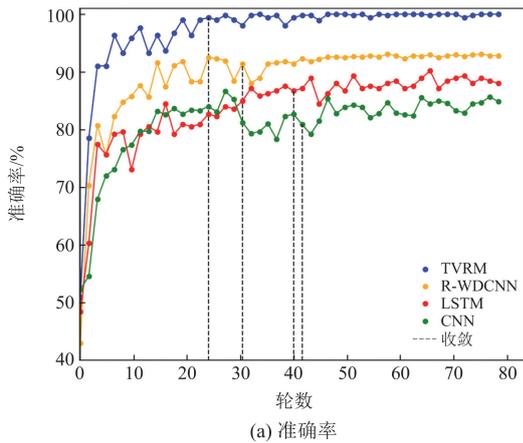


图 4 不同模型准确率和训练损失随训练轮数的变化趋势
Fig. 4 Trends of accuracy and training loss with number of training rounds for different models

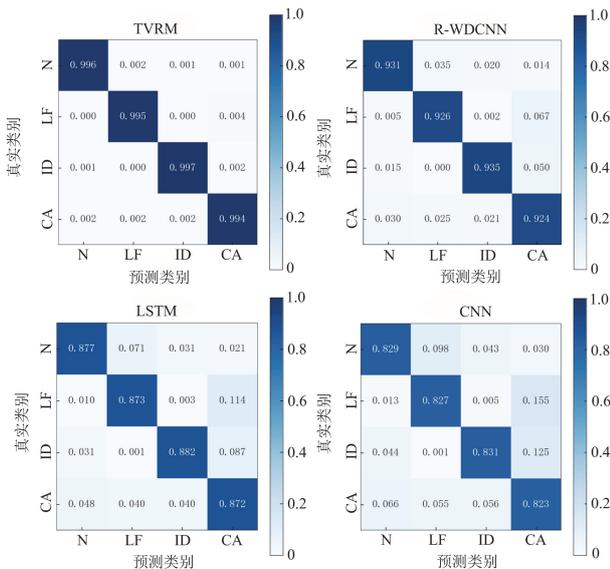


图 5 不同模型在测试集上的混淆矩阵
Fig. 5 Confusion matrix for different models on the test set

比结果。从结果可以看出, TVRM 模型在所有评估指标上均表现出色, 其各项指标均超过了 99%, 明显优于其他对比模型。结果表明, TVRM 模型在故障诊断任务中具备更强的抗干扰能力、更优的泛化能力以及更强的分类性能, 为复杂工况下的故障诊断提供了一种更加高效和可靠的解决方案。

表 5 不同算法模型诊断结果

Table 5 Diagnostic results of different algorithmic models

网络名称	准确率/%	精确率/%	召回率/%	F1 指数/%
TVRM	99.72	99.74	99.70	99.72
R-WDCNN	93.37	93.06	93.04	93.04
MFCC-LSTM	87.62	87.51	86.67	87.09
MFCC-CNN	82.79	82.77	82.69	82.73

4.4 消融实验

4.4.1 声纹脊线化特征消融实验

在实际应用中, 变压器声纹识别系统多部署于嘈杂环境, 且常采用算力和存储受限的嵌入式传感器, 因此压缩特征维数对提升模型性能至关重要。本文在不同信噪比下对比相同网络结构的多种特征提取方法, 验证基于脊线化方法在噪声环境中的稳定性和抗干扰能力。本文收集并处理了多种自然白噪声环境下的音频数据, 信噪比(SNR)分别为-13 dB、-12 dB、0 dB、1 dB 和 2 dB。同时, 为对比分析人工添加白噪声与真实环境噪声在去噪效果上的差异性及去噪算法对其的适用性, 还采集了雷雨天气下的真实环境噪声(SNR 为-12 dB)进行对比分析。实验对比了 3 种 TVRM 算法下的识别准确率: 基于脊线化特征的 TVRM, 基于 MFCC 和 LPCC 特征提取的 TVRM, 以及结合粒子群优化 VMD 的 TVRM, 并通过不同信噪比条件下的识别准确率进行性能评估。对比结果如表 6 所示。

表 6 不同特征方法在不同信噪比下的识别准确率

Table 6 Recognition accuracy of different feature methods under various SNRs

信噪比/ dB	识别准确率/%			
	TVRM (MFCC)	TVRM (LPCC)	TVRM (PSO-VMD)	TVRM (脊线化)
-13	85.95	83.75	89.59	99.59
-12(真)	88.02	88.33	91.51	99.36
-12	87.76	88.63	91.92	99.72
0	91.42	91.83	92.63	99.81
1	92.64	93.43	93.07	99.87

从表 6 中可以看出, 通过对真实环境中的-12 dB 噪声数据进行测试, TVRM(脊线化)在真实噪声条件下的表现(99.36%)与在人工添加白噪声条件下的

表现(99.72%)高度吻合, 验证了人工噪声仿真在实验中的可行性。此外, TVRM(脊线化)在所有信噪比条件下(-13~1 dB)的故障诊断准确率显著高于基于传统特征提取方法(MFCC 和 LPCC)的模型, 尤其是在低信噪比的情况下, 脊线化特征展现出更加明显的优势。例如, 在-13 dB 时, TVRM(脊线化)达到了 99.59%的准确率, 而 MFCC 和 LPCC 的准确率仅为 85.95%和 83.75%。虽然采用 PSO-VMD 特征提取的 TVRM 在低信噪比条件下也取得了较好的性能(如在-13 dB 时的准确率为 89.59%), 但仍低于脊线化方法。综上所述, 脊线化特征的压缩显著提高了模型在少样本条件下的故障诊断准确率, 通过优化特征质量而非数量, 有效地提升了模型的泛化能力。

为了验证进行声纹脊线化优化后信号的保真率, 本文采用 PSNR 和 SSIM 作为评判指标, 对收集的真实数据进行测评, 结果如图 6 所示。图中展示了绝缘放电故障在低噪声(SNR 为 2 dB)和高噪声(SNR 为-12 dB)环境下的三维频谱图。本文采用最小-最大归一化方法对原始时频谱图的信号幅值进行归一化处理, 将其线性缩放至[0,1]区间, 便于不同噪声条件下信号幅度的直观对比。图 6 中红色虚线为脊线化特征提取后的主要脊线分布趋势, 并标注了每种环境下对应的 PSNR 和 SSIM 指标。左侧图为低信噪比(SNR 为 2 dB), PSNR 为 32.12, SSIM 为 0.937; 右侧为高信噪比(SNR 为-12 dB), PSNR 为 29.46, SSIM 为 0.89。结果表明, 在高噪声环境下经脊线优化处理后, 谱图特征的 PSNR 和 SSIM 指标依然较高, 显示出脊线特征具有优异的鲁棒性和高保真度。

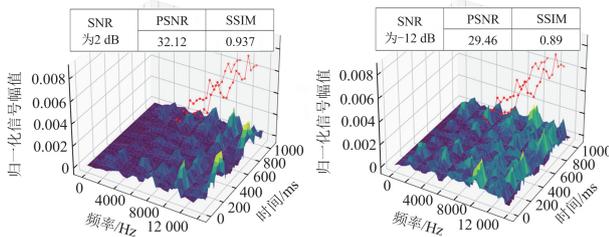


图 6 脊线化特征的抗噪稳定性

Fig. 6 Anti-noise stability of ridged features

4.4.2 选择性编码器消融实验

尽管脊线化处理后的特征具备较强的聚焦性和较高的表达能力, 但在复杂的声纹识别任务中, 这些特征可能无法充分满足元学习网络对时频谱图多频维度的要求。鉴于元学习网络在不同频率区域对特征精确性和适应性的高需求, 本研究旨在验证 SE

模块在增强特征表现方面的关键作用。采用统一的算法模型, 并对比了图像处理常用的 CNN 编码器和时序数据处理常用的 LSTM 编码器。实验结果如表 7 所示, 引入 SE 模块后, 模型收敛轮数减少 38% (从 39 轮降至 24 轮), 并且模型准确率提升 7.37%。

表 7 编码器消融实验

Table 7 Ablation study of encoders

网络名称	收敛轮数	训练准确率/%
TVRM(SE)	24	99.72
TVRM(CNN)	39	92.35
TVRM(LSTM)	35	92.87

同时为了直观表示 TVRM 网络强大的特征表征能力, 本文利用 t-SNE(t-distributed stochastic neighbor embedding)对各个网络模型在测试集上的诊断结果进行可视化处理。具体而言, 选择各个网络在进入全连接层之前的特征向量作为 t-SNE 的输入, 以此捕捉并展示不同网络模型在高维特征空间中的分布情况。通过 t-SNE 的降维处理, 能够有效地将高维特征映射到低维空间, 揭示出不同模型在特征提取方面的相似性与差异性。t-SNE 特征可视化对比结果如图 7 所示。CNN 和 LSTM 模型的特征分布存在较大重叠, R-WDCNN 表现出一定程度的类间分离, 而 TVRM 模型的类间分离度最高, 边界清晰, 表明其具备更强的特征区分能力和泛化性能, 在复杂环境中实现了更高的诊断准确率。

4.4.3 距离函数消融实验

本研究设计了一组消融实验, 旨在评估不同距离函数对模型精度的影响, 重点分析 DFD 在梯度优化过程中, 处理特征尺度差异以解决小样本问题的优势。实验使用 4-Way 10-Shot 和 4-Way 50-Shot 数据集(分别记为数据集 DataA 和 DataB)进行模型训练, 随后使用与训练集不同的数据集进行验证测试, 以确保测试数据的独立性和结果的可靠性。每个模型在验证集上进行了 10 次独立实验, 记录并计算其平均精度。

在实验中, 对比了 4 种距离函数组合方式: 1 表示仅使用欧氏距离, 2 表示仅使用余弦距离, 3 表示仅使用 DFD, 4 表示欧氏距离和余弦距离的融合。通过对比不同距离函数下的分类准确率, 重点评估了 DFD 在处理脊线化频谱图特征尺度差异和小样本分布时的有效性。

实验结果如表 8 所示, DFD 在不同度量函数中的表现最佳, 显著提升了模型在不同小样本数据集上的分类准确率, 特别是在 DataB 上达到了 98.64% 的最高准确率。这表明, DFD 在处理脊线化后的谱

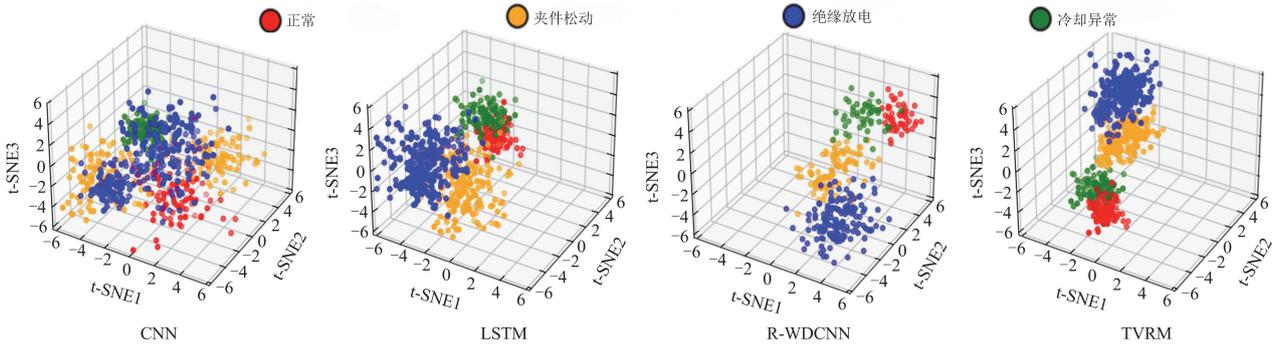


图7 不同算法模型下 t-SNE 特征分布

Fig. 7 Distribution of t-SNE features under different algorithmic models

表8 度量函数消融实验结果

Table 8 Ablation experiment result of metric function

数据集	不同度量函数的分类准确率/%			
	1	2	3	4
DataA	85.30	89.23	93.43	81.58
DataB	88.60	90.73	98.64	83.45

图特征时,通过自适应调整特征间的相似度计算方式,有效缓解了由于特征分布尺度不一致所带来的匹配困难,从而显著提升了模型在小样本条件下的判别性能。

4.5 噪声环境下模型识别效果

本实验针对工业场景中的数据稀缺问题,评估提出的小样本学习方法在含噪环境下的故障诊断性能。测试集构建采用真实设备音频叠加6种强度自然白噪声(SNR: -14~+2dB),最终以诊断准确率为指标量化分析抗噪能力与稳定性。

通过表9中的数据可以发现,在不同的信噪比条件下,R-WDCNN、MFCC-LSTM和MFCC-CNN在不同信噪比下的性能存在显著差异。当信噪比为-14 dB时,MFCC-LSTM和MFCC-CNN的准确率分别为82.39%和80.13%,明显低于R-WDCNN的89.15%。虽然随着信噪比的提升,这些模型的准确

表9 不同算法模型在各信噪比下的识别准确率

Table 9 Recognition accuracy of different models under various SNRs

信噪比/ %	识别准确率/%			
	TVRM	R-WDCNN	MFCC-LSTM	MFCC-CNN
-14	99.32	89.15	82.39	80.13
-13	99.59	91.26	84.71	82.04
-12	99.72	93.37	87.62	82.79
0	99.81	93.51	88.01	83.42
1	99.87	93.93	89.17	83.96
2	99.93	94.32	89.93	84.29

率持续提升,但当信噪比为-12 dB时,MFCC-LSTM和MFCC-CNN的识别准确率分别达到87.62%和82.79%。相比之下,TVRM模型在所有信噪比下均表现出显著优势,随着信噪比的逐步提升,TVRM的识别准确率始终维持在较高水平,并在2 dB时达到99.93%,充分验证了其在复杂噪声环境下的抗干扰能力。

4.6 模型的泛化性

在实际应用中,由于数据分布不均和工况环境多变,收集变压器各类故障的大规模样本通常不切实际。为验证TVRM模型在无需完整模型训练的情况下对新工况故障数据的适应性和泛化能力,本文采用了K-Way N-Shot方法,实验设计包括在正常工况下用真实数据对模型进行训练,并在过载、谐波、高温等工况下对其性能进行验证。通过对比模型在正常工况训练集上的学习效果与不同工况验证集上的测试准确率,评估其对实际运行条件变化的泛化能力。

实验设置了4种真实故障数据的K-Way N-Shot配置:3-Way 10-Shot、3-Way 30-Shot、4-Way 10-Shot和4-Way 30-Shot。训练阶段使用正常工况数据,验证阶段使用不同工况数据。为确保结果可靠,所有实验均在相同的噪声环境(SNR为-12 dB)下进行,并进行了10次独立实验,每次实验中,在相同配置下进行5次随机重复训练测试,最终将其平均准确率作为该次实验结果。

实验结果如图8所示,TVRM模型在不同工况下表现出良好的泛化能力,尤其在正常和谐波工况下较为稳定。在高温工况下,模型准确率略有下降,表明极端条件下适应性有待提升。但在不同K-Way N-Shot配置下,模型在过载、谐波、高温等复杂工况中分类准确率仍保持在95%以上,验证了该模型具有无需重新训练即可稳定适应新工况的能力。未

来研究应聚焦特定条件优化, 以提升模型在极端工况下的鲁棒性和可靠性。

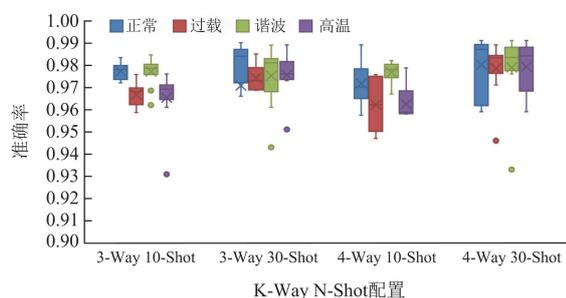


图 8 不同工况下的泛化验证

Fig. 8 Generalization test across operating conditions

5 结论

为实现极端环境及少样本条件下的变压器声纹故障准确诊断, 本文基于度量元学习方法, 提出了一种结合声纹脊线化与元学习的变压器故障诊断方法。对不同工况下收集的声纹数据进行诊断分析后, 得出以下结论。

1) 提出了变压器声纹特征脊线化处理方法, 通过时频谱图特征算法对特征进行精炼, 通过带通滤波器与 K 均值聚类协同优化, 实现了频率特征的增强选择和形态特征的有效压缩, 显著提升了特征的质量与可解释性。

2) 选择性特征编码方式显著提升了脊线化压缩特征的精确性和适应性, 实现了在不同频率区域更高的特征表达能力和区分度。通过选择性优化卷积核及其膨胀率, 模型在复杂声纹识别任务中的收敛轮数从 35 轮以上缩短至 24 轮, 准确率提升了 6.85%, 满足了元学习网络对高精度特征的需求。

3) 提出基于 OD-Reptile 的元学习方法, 采用样本分配策略优化内循环训练过程, 引入基于动态度量函数的外循环梯度冲突衰减方法, 从而实现更高效的参数优化, 有效提升模型在少样本条件下的适应性和泛化能力, 并在不同噪声环境下保持 99% 以上的准确率。然而, 模型在高温工况下的泛化能力仍有不足, 未来研究应聚焦极端工况的优化, 以增强模型的鲁棒性和可靠性。

参考文献

[1] 邓祥力, 廖玥琳, 朱宏业, 等. 基于数字孪生模型电流动态时间规整差异度的变压器早期故障辨识[J]. 电力系统保护与控制, 2023, 51(12): 156-167.
DENG Xiangli, LIAO Yuelin, ZHU Hongye, et al. Early fault identification for a transformer based on current dynamic time warping difference of a digital twin model[J].

Power System Protection and Control, 2023, 51(12): 156-167.

[2] 罗文萱. 基于胶囊神经网络的电力变压器故障诊断方法研究[J]. 高压电器, 2024, 60(5): 92-98.
LUO Wenxuan. Research on fault diagnosis method of power transformer based on capsule networks[J]. High Voltage Apparatus, 2024, 60(5): 92-98.

[3] 邹阳, 陈啸轩, 张云霄, 等. 基于界面电荷极化特性的变压器油纸绝缘寿命预测方法研究[J]. 电力系统保护与控制, 2024, 52(7): 138-148.
ZOU Yang, CHEN Xiaoxuan, ZHANG Yunxiao, et al. A life prediction method of transformer oil-paper insulation based on interfacial charge polarization characteristics[J]. Power System Protection and Control, 2024, 52(7): 138-148.

[4] 刘庆珍, 张溢, 鄢仁武. 基于拉曼光谱数据处理和谱峰识别的变压器油绝缘老化研究[J]. 电力系统保护与控制, 2024, 52(8): 158-166.
LIU Qingzhen, ZHANG Yi, YAN Renwu. Transformer oil insulation aging based on Raman spectral data processing and peak identification[J]. Power System Protection and Control, 2024, 52(8): 158-166.

[5] 周家玉, 侯慧娟, 盛戈峰, 等. 状态参量关联规则挖掘及深度学习融合的变压器故障诊断算法[J]. 高压电器, 2023, 59(3): 108-115.
ZHOU Jiayu, HOU Huijuan, SHENG Gehao, et al. Transformer fault diagnosis algorithm based on association rules mining of state parameters and deep learning[J]. High Voltage Apparatus, 2023, 59(3): 108-115.

[6] WEI J X, FAN X, CHUN M T, et al. Suppression strategy for the inrush current of a solid-state transformer caused by the reclosing process[J]. Protection and Control of Modern Power Systems, 2023, 8(4): 1-13.

[7] 郝艳, 咸日常, 冷学冰, 等. 基于电压、电流不平衡度差值的干式变压器匝间短路故障识别方法[J]. 电力系统保护与控制, 2023, 51(4): 12-21.
HAO Yan, XIAN Richang, LENG Xuebing, et al. Identification method for an inter-turn short circuit fault of a dry-type transformer based on voltage and current imbalance difference[J]. Power System Protection and Control, 2023, 51(4): 12-21.

[8] HUSSAIN A, LEE S J, CHOI M S, et al. An expert system for acoustic diagnosis of power circuit breakers and on-load tap changers[J]. Expert Systems with Applications, 2015, 42(24): 9426-9433.

[9] 万可力, 马宏忠, 崔佳嘉, 等. 基于 Mel-GADF 与 ConvNeXt-T 的变压器铁心松动故障诊断方法[J]. 电力自动化设备, 2024, 44(3): 217-224.
WAN Keli, MA Hongzhong, CUI Jiajia, et al. Fault

- diagnosis method of transformer core loosening based on Mel-GADF and ConvNeXt-T[J]. *Electric Power Automation Equipment*, 2024, 44(3): 217-224.
- [10] 谭贵生, 曹生现, 赵波, 等. 基于关联规则与变权重系数的变压器状态综合评估方法[J]. *电力系统保护与控制*, 2020, 48(1): 88-95.
- TAN Guisheng, CAO Shengxian, ZHAO Bo, et al. An assessment of power transformers based on association rules and variable weight coefficients[J]. *Power System Protection and Control*, 2020, 48(1): 88-95.
- [11] 于达, 张玮, 王辉. 基于 LSTM 神经网络的油浸式变压器异常声纹诊断方法研究[J]. *智慧电力*, 2023, 51(2): 45-52.
- YU Da, ZHANG Wei, WANG Hui. Abnormal voiceprint diagnosis method of oil-immersed transformer based on LSTM neural network[J]. *Smart Power*, 2023, 51(2): 45-52.
- [12] 王荣昊, 李喆, 孙正, 等. 基于 FISVDD 与 GRU 的变压器声纹识别技术[J]. *高电压技术*, 2022, 48(11): 4546-4556.
- WANG Ronghao, LI Zhe, SUN Zheng, et al. Transformer voiceprint recognition technology based on FISVDD and GRU[J]. *High Voltage Engineering*, 2022, 48(11): 4546-4556.
- [13] 齐子豪, 仝杰, 张中浩, 等. 基于多粒度知识特征和 Transformer 网络的电力变压器故障声纹辨识方法[J]. *中国电机工程学报*, 2025, 45(4): 1311-1322, 8.
- QI Zihao, TONG Jie, ZHANG Zhonghao, et al. A voiceprint classification method for power transformer fault identification based on multi-granularity knowledge features and transformer network[J]. *Proceedings of the CSEE*, 2025, 45(4): 1311-1322, 8.
- [14] 李金科. 元学习在旋转机械故障诊断中的应用综述[J]. *科技与创新*, 2023(18): 176-178.
- [15] CHEN F, YAN J, LIU Y, et al. A novel meta-learning approach for few-shot short-term wind power forecasting[J]. *Applied Energy*, 2024, 362.
- [16] 董美霖. 基于多尺度膨胀卷积的多光谱与全色图像融合方法研究[D]. 重庆: 重庆邮电大学, 2022.
- DONG Meilin. Multispectral and panchromatic image fusion method based on multiscale dilated convolution[D]. Chongqing: Chongqing University of Posts and Telecommunications, 2022.
- [17] 司祯祯. 傅里叶变换与小波变换在信号去噪中的应用[J]. *电子设计工程*, 2011, 19(4): 155-157.
- SI Zhenzhen. Application of Fourier transform and wavelet transform in signal denoising[J]. *Electronic Design Engineering*, 2011, 19(4): 155-157.
- [18] 王博闻. 电力变压器典型异常状态声纹诊断技术[D]. 北京: 华北电力大学, 2022.
- WANG Bowen. Acoustic signal diagnosis technology for typical anomalous state of power transformer[D]. Beijing: North China Electric Power University, 2022.
- [19] PAVEL Z, MICHAL S, BORIS S, et al. Cascade structure of narrow equiripple bandpass FIR filters[J]. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2017, 64(4).
- [20] WEI J K, JI Y X, JUN J X. Generative knowledge-based transfer learning for few-shot health condition estimation[J]. *Complex & Intelligent Systems*, 2022, 9(1): 965-979.
- [21] 张重远, 胡焕, 程槐号, 等. 基于欧氏距离分析的电力变压器绕组变形程度与类型的诊断方法[J]. *高压电器*, 2020, 56(1): 224-230.
- ZHANG Chongyuan, HU Huan, CHENG Huaihao, et al. Diagnostic method to determine degree and type of winding deformation in power transformer based on euclidean distance[J]. *High Voltage Apparatus*, 2020, 56(1): 224-230.
- [22] 汪颖, 禹华西, 马明, 等. 基于余弦相似度的电压暂降/暂升类型模式匹配方法[J]. *水电能源科学*, 2020, 38(4): 171-175.
- WANG Ying, YU Huaxi, MA Ming, et al. Pattern matching method of voltage dip/swell type based on cosine similarity[J]. *Water Resources and Power*, 2020, 38(4): 171-175.
- [23] 段晓军, 王仁, 迟主升. 换流变压器不同工况下的铁心磁特性研究[J]. *机电工程技术*, 2022, 51(9): 280-284.
- DUAN Xiaojun, WANG Ren, CHI Zhusheng. Study on the magnetic characteristics of core of converter transformer under different working conditions[J]. *Mechanical & Electrical Engineering Technology*, 2022, 51(9): 280-284.
- [24] QIN H, LIU M, WANG J, et al. Adaptive diagnosis of DC motors using R-WDCNN classifiers based on VMD-SVD[J]. *Applied Intelligence*, 2021, 51: 4888-4907.

收稿日期: 2024-09-07; 修回日期: 2024-11-30

作者简介:

曲朝阳(1964—), 男, 博士, 教授, 研究方向为电力大数据处理、电力信息物理融合系统的安全评估与预警技术、新一代人工智能技术及智能电网应用等; E-mail: 824937289@qq.com

刘谊豪(1997—), 男, 通信作者, 硕士, 研究方向为电力大数据处理、电力设备故障检测。E-mail: 2625601584@qq.com

(编辑 张颖)