

采用多级传感器融合网络的强噪声下高压断路器故障诊断方法研究

王艳新, 张正润, 闫静, 刘志远, 耿英三, 王建华

(西安交通大学电工材料电气绝缘全国重点实验室, 710049, 西安)

摘要: 针对强噪声工况下高压断路器机械故障信号易受背景干扰、多源信息利用不足及小样本特征判别能力弱的问题, 提出一种基于多级传感器融合网络的诊断方法。该方法从数据级、特征级和决策级三个层面构建多级融合框架, 实现多源信息的协同建模与鲁棒诊断。首先, 在数据级实现同构传感器信号多通道协同表征, 增强原始信号中故障信息的可辨识度。其次, 在特征级构建以小波卷积为核心的特征学习网络, 对异构传感器信号进行联合时频建模, 利用小波卷积在多尺度下抑制背景噪声干扰, 保持良好的特征提取稳定性。最后, 在决策级基于信息熵对多传感器诊断结果进行可信度加权融合, 降低单一传感器误判对整体决策的影响, 并通过时间-频率原型对比学习增强类内聚集和类间分离。研究结果表明: 相比最优特征级融合方法, 精确率、召回率和F1值分别提高了2.58%、4.85%和2.70%; 在-15 dB强噪声下, F1值仍高于90%; 相比传统对比学习模型, 3项指标分别提高了6.52%、9.24%和6.87%, 从而验证了方法的鲁棒性与小样本诊断的有效性。该研究为实现强噪声与小样本条件下高压断路器机械故障的诊断提供了一种有效解决方法。

关键词: 高压断路器; 故障诊断; 多传感器融合; 小样本; 对比学习

中图分类号: TM561; TP18 **文献标志码:** A

DOI: 10.7652/xjtubXXXXXX001 **文章编号:** 0253-987X(XXXX)XX-0001-12

Fault Diagnosis of High-Voltage Circuit Breakers under Strong Noise Based on a Multi-Level Sensor Fusion Network

WANG Yanxin, ZHANG Zhengrun, YAN Jing, LIU Zhiyuan, GENG Yingsan, WANG Jianhua

(State Key Laboratory of Electrical Insulation for Power Equipment, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To address the issues of mechanical fault signals of high-voltage circuit breakers being susceptible to background interference under strong noise conditions, insufficient utilization of multi-source information, and weak discriminative capability under small-sample conditions, a diagnostic method based on a multi-level sensor fusion network is proposed. This method constructs a multi-level fusion framework at three levels—data level, feature level, and decision level—to achieve collaborative modeling and robust diagnosis of multi-source information. First, at the data level, multi-channel collaborative representation of homogeneous sensor signals is realized to enhance the identifiability of fault information in the raw signals. Second, at the feature level, a feature learning network centered on wavelet convolution is built to perform joint time-frequency modeling of

heterogeneous sensor signals. The wavelet convolution suppresses background noise interference at multiple scales while maintaining stable feature extraction. Finally, at the decision level, credibility-weighted fusion of multi-sensor diagnostic results is performed based on information entropy, reducing the impact of misjudgment by a single sensor on the overall decision. In addition, time-frequency prototype contrastive learning is employed to enhance intra-class compactness and inter-class separation. The results shows that, compared with the optimal feature-level fusion method, the precision, recall, and F1-score are improved by 2.58%, 4.85%, and 2.70%, respectively. Under strong noise at -15 dB, the F1-score remains above 90%. Compared with traditional contrastive learning models, the three metrics are increased by 6.52%, 9.24%, and 6.87%, respectively, verifying the robustness and small-sample diagnostic effectiveness of the proposed method. This study provides an effective solution for fault diagnosis of high-voltage circuit breakers under strong-noise and small-sample conditions.

Keywords: high-voltage circuit breaker; fault diagnosis; multi-sensor fusion; small-sample learning; contrastive loss

高压断路器作为电力系统中重要的保护与控制设备,其运行状态直接影响电网的安全稳定运行^[1]。随着特高压输电工程和新型电力系统的快速发展,高压断路器的运行工况日趋复杂,在长期服役过程中,易受到机械磨损、结构松动、部件老化及装配偏差等因素的影响,从而引发拒动、误动等机械故障^[2-4]。因此,开展高压断路器机械故障诊断方法研究具有重要的工程意义。

振动、声音和电流等监测信号能够反映断路器的运行状态,其中,振动信号对机械结构变化最为敏感,并已广泛应用于机械故障诊断领域^[5-7]。传统诊断方法主要依赖信号处理与浅层机器学习模型,通过人工构造特征实现故障识别,具有一定可解释性,但对特征设计经验的依赖性较强,在复杂工况和强噪声环境下的性能有限^[8]。近年来,深度学习方法能够从原始监测数据中自动学习故障特征,在诊断精度和自动化水平方面取得了较好的效果^[9-10]。然而,现有研究大多基于单一传感器开展分析,难以充分利用多源监测数据的互补信息,在复杂工况下的诊断稳定性仍有待提升。

在实际工程应用中,高压断路器通常配置多个传感器,虽然不同传感器在测量对象、安装位置及响应特性方面存在差异,但多源信息之间也兼具相关性与互补性。多传感器融合技术能够综合利用不同信号的优势,提升故障特征表征能力,已成为高压断路器状态监测和诊断的重要研究方向^[11]。根据融合层级不同,多传感器融合方法主要包括数据级、特征级和决策级融合^[12]。其中,数据级融合能够保留较完整的原始信息,但易受到噪声干扰;

特征级融合有利于增强特征判别能力,但可能造成部分信息损失;决策级融合具有较好的抗干扰能力,但其性能受融合策略影响较大。现有研究多聚焦于单一融合层级,难以兼顾信息完整性、抗噪性与诊断可靠性。

与此同时,由于现场高压断路器长期处于正常运行状态,故障样本获取困难且类别分布不均衡,小样本问题普遍存在^[13]。在样本不足条件下,深度学习模型容易出现过拟合,从而导致泛化能力的下降。近年来,原型学习和对比学习等方法通过构建判别性特征空间提升小样本的学习能力^[14-17],但在多源异构数据条件下,其诊断性能仍存在进一步提升的空间。此外,现场断路器运行环境复杂,背景噪声强烈,不同传感器信号受噪声影响程度存在差异,单一特征提取模型在极端噪声条件下往往难以兼顾诊断精度与鲁棒性。如何在多源传感融合过程中有效抑制强背景噪声干扰,同时保持对微弱机械故障特征的敏感性,是提升断路器机械故障诊断实用性的又一重要挑战。

针对上述问题,本文提出一种基于多级传感器融合网络的高压断路器机械故障诊断方法。通过构建数据级、特征级和决策级协同融合框架,实现多源监测信息的逐级融合。首先,设计多通道协同表征的数据级融合,对多通道信息进行整合,增强原始信号的故障表征能力;其次,采用小波卷积开展时频联合特征学习,在特征级对异构传感器信号进行时频联合建模,增强模型对噪声干扰的鲁棒性;接着,结合基于信息熵的决策融合策略,提高诊断结果的稳定性与可靠性;最后,进一步引入时间-

频率原型对比损失,提升小样本条件下故障特征的判别能力。实验结果表明,所提出方法在强噪声和小样本条件下均具有较好的诊断性能。

1 多级传感器融合网络

高压断路器机械故障诊断面临多源监测信息利用不充分、强背景噪声干扰以及故障样本有限等问题。为提高复杂工况下的诊断准确性与可靠性,需要实现多源信息的协同建模、关键故障特征的鲁棒提取以及小样本条件下的有效特征学习。针对上述问题,本文提出一种基于多级传感器融合网络的高压断路器机械故障诊断方法,整体结构如图1所示。图中, M 为振动传感器通道总数, C 为线圈电流传感器总数。




图1 采用多级传感器融合网络的高压断路器机械故障诊断框架

Fig. 1 Mechanical fault diagnosis framework for high-voltage circuit breakers using a multi-level sensor fusion network

由图可知,该方法从数据级、特征级和决策级三个层面构建多级融合框架,并结合时间-频率原型对比学习机制实现小样本特征优化。数据级融合侧重信号质量增强,特征级融合侧重判别建模,决策级融合侧重诊断可信性约束。在增强信号抗噪能力的同时,充分挖掘多源信息的互补特性,并引入对比学习^[18]约束强化类别特征的聚类与分离能

力,改善小样本条件下的特征判别性能。通过各层级的协同作用,实现高压断路器机械故障的鲁棒诊断。

1.1 基于多通道协同表征的数据级融合

在高压断路器机械故障监测中,通常布置多个同构振动传感器以获取设备运行状态信息。然而,由于传感器安装位置及振动传播路径不同,各通道信号在故障敏感性、噪声水平及信息质量方面存在差异。若直接将各通道信号输入诊断模型,容易引入冗余信息和噪声干扰,影响故障特征表征效果。为此,本文提出一种基于多通道协同表征的数据级融合方法,在保持信号时序结构不变的基础上,对多通道振动信号进行自适应加权融合,以增强故障相关信息并抑制低质量通道的干扰。

从机械响应机理的角度而言,高压断路器在正常运行状态下,其振动信号通常呈现稳定的周期结构;当传动机构发生松动、磨损或卡涩等故障时,振动信号中会出现周期性冲击特征,并在包络谱中表现为特征频率及其倍频成分。不同传感器对上述特征的响应强度存在差异,因此有必要从冲击特征、调制特征及能量分布等方面对各通道信号质量进行综合评估。

首先,采用改进的基尼系数(GI_3)指标 I_{GI3} 对信号的冲击稀疏性进行度量^[19],该指标相较于传统峭度对随机脉冲干扰更为鲁棒,能够有效刻画机械故障引起的非平稳冲击特征。其次,引入包络谱信息熵 E 对信号调制特性进行评估,信息熵越小,信号中故障特征频率及其谐波分量越突出,从而可从频域角度反映其故障相关性^[20]。进一步结合信号能量特性,构建综合指标 I_l 对各传感器通道的信号质量进行统一量化,表达式为

$$I_l = \frac{I_{GI3,l}}{E_l + \epsilon} \|x_l\|_2 \quad (1)$$

式中:下标 l 表示振动传感器通道索引; x_l 为第 l 个振动通道信号; $\|\cdot\|_2$ 为信号的 L_2 范数; ϵ 为防止分母为0的正小常数。

基于上述复合指标,对同一时刻采集的多通道信号自适应分配融合权 w_l ,表达式为

$$w_l = \frac{I_l}{\sum_{i=1}^M I_i}; \sum_{i=1}^M w_i = 1 \quad (2)$$

式中: M 为振动传感器通道总数; j 为分母中的求和索引。

按照加权求和方式完成数据级融合后,得到融

合后的原始信号 $x_{\text{fusion}}(t)$ 表达式为

$$x_{\text{fusion}}(t) = \sum_{l=1}^M w_l x_l(t) \quad (3)$$

式中: t 为时间。

通过上述过程,可实现多通道振动信息的协同利用,在数据层面增强故障敏感通道的贡献并抑制低可信通道的影响,从而提高原始信号中故障特征的可辨识性,为后续时频特征学习与诊断决策提供可靠输入。

1.2 基于小波卷积多源时频联合的特征级融合

在完成数据级融合后,仍需进一步挖掘振动、触头行程及分合闸线圈电流等异构传感器信号之间的互补信息。其中,振动信号反映机构冲击与结构响应特征,触头行程和线圈电流分别表征机械运动过程与电磁驱动状态,不同信号在时域和频域特征上具有明显差异。

为实现异构信息的统一建模,本文在特征级融合层构建基于小波卷积^[21]的多源时频特征学习网络,将小波分析与深度卷积结构相结合,对多源信号开展多尺度时频特征提取。小波变换能够通过尺度伸缩与平移操作刻画信号中的瞬态冲击及周期调制特征。不同于传统固定小波基分析方法,本文将连续小波变换嵌入网络结构,构建共享小波卷积层,对不同传感器信号进行统一的时频特征提取。

设输入的异构多源信号样本矩阵表示为 $X_k = [x_{k,1}, x_{k,2}, \dots, x_{k,S}]$, 其中,下标 k 表示样本索引; S 表示参与融合的异构信号源总数。对第 k 个样本中的第 s 路信号进行小波卷积,其输出 $F_{k,s}^{(\mu,c)}(t)$ 可表示为

$$F_{k,s}^{(\mu,c)}(t) = (\psi_{\mu,c} * x_{k,s})(t) = \int_{-\infty}^{+\infty} \psi_{\mu,c}(\tau) x_{k,s}(t - \tau) d\tau \quad (4)$$

式中: $\psi_{\mu,c}(t)$ 为具有尺度参数 c 和位移参数 μ 的小波核函数; $*$ 为卷积运算符; $x_{k,s}$ 为第 k 个样本中第 s 路信号的时间序列向量。将各采样时刻的卷积输出按时间顺序排列,可得到相应的小波卷积特征向量 $F_{k,s}^{(\mu,c)}$ 。

在获得各传感器时频特征后,为增强多源信息之间的关联表征能力,本文构建了多源时频特征融合模块。首先,在传感器维度引入门控重加权机制,利用多源上下文信息对各通道特征进行自适应调节;随后,在时间维度引入轻量化注意力机制,对关键时间片段进行加权建模,以突出与故障状态相关的时频特征。最后,面向多源关联的时-频特征融

合结果 $F_{k,\text{fusion}}$ 可统一表示为

$$F_{k,\text{fusion}} = \mathcal{F}_{\text{time}}(\mathcal{F}_{\text{sensor}}(\{F_{k,s}\}_{s=1}^S)) \quad (5)$$

式中: $\{F_{k,s}\}_{s=1}^S$ 表示第 k 个样本中全部 S 路信号的时频特征组; $\mathcal{F}_{\text{sensor}}(\cdot)$ 表示沿信号源维度进行多源协同融合操作; $\mathcal{F}_{\text{time}}(\cdot)$ 表示沿时间维度进行时间序列关联建模操作。

通过上述过程,实现振动、触头行程及线圈电流等多源信息的联合表征,为后续故障状态判别提供融合特征输入。

1.3 基于信息熵的决策级融合策略

在强噪声工况下,不同传感器对应的诊断结果存在差异,固定权重融合难以反映各传感器对当前样本的判别能力。为此,本文在决策层引入基于信息熵^[22]的自适应融合策略,根据各传感器输出结果的不确定性进行自适应加权,融合流程如图2所示。图中, $P_{k,s',n}$ 为第 s' 个通道对第 k 个样本属于第 n 类故障的原始输出得分; $\hat{P}_{k,s',n}$ 为经过 Softmax 归一化后得到的类别预测概率; N 为故障类别数量; $\phi_{k,s'}$ 为第 s' 个通道对第 k 个样本预测结果的信息熵; $\omega_{k,s'}$ 为第 s' 个通道的融合权重; $P'_{k,n}$ 为多通道加权融合后,第 k 个样本属于第 n 类故障的最终预测概率; Softmax 为一种指数归一化函数,可将模型输出的未归一化得分映射为 $[0,1]$ 范围内的概率分布,并保证各类别概率之和为1。




图2 基于信息熵的决策级融合策略

Fig. 2 Decision-level fusion strategy based on information entropy

具体而言,设同一时刻采集的多源传感器样本构成样本集合 $\tilde{X}_k = [X_{k,1}, X_{k,2}, \dots, X_{k,S}]$, 各传感器

信号经对应诊断模型输出故障类别预测结果。经 Softmax 归一化后可得 $\hat{P}_{k,s',n}$ 的表达式为

$$\hat{P}_{k,s',n} = \frac{\exp(P_{k,s',n})}{\sum_{n=1}^N \exp(P_{k,s',n})} \quad (6)$$

进一步,引入信息熵对各通道的判别不确定性进行量化,表达式为

$$\phi_{k,s'} = - \sum_{n=1}^N \hat{P}_{k,s',n} \log \hat{P}_{k,s',n} \quad (7)$$

信息熵越小,表明该通道对当前样本的判别不确定性越低,其诊断结果可信度越高。

基于上述判别不确定性指标,对各通道信息熵进行归一化处理以获得样本级融合权重,表达式为

$$\omega_{k,s'} = \frac{\exp(-\phi_{k,s'})}{\sum_{s'=1}^{2S} \exp(-\phi_{k,s'})} \quad (8)$$

由此,在多通道诊断结果存在冲突时,低不确定性(高可信度)通道的决策贡献将被自适应增强。

最终,决策级融合输出可表示为

$$P'_{k,n} = \sum_{s'=1}^{2S} \omega_{k,s'} \hat{P}_{k,s',n} \quad (9)$$

在此基础上,采用交叉熵损失函数^[23]对融合输出进行误差反馈学习,表达式为

$$\mathcal{L}_{CE} = - \frac{1}{K} \sum_{k=1}^K \sum_{n=1}^N y_{k,n} \log(P'_{k,n}) \quad (10)$$

式中: $\mathcal{L}_{CE}$ 为决策级融合模型的平均交叉熵损失函数; K 为训练样本数; $y_{k,n}$ 为真实类别标签。

通过信息熵权重分配机制,实现多传感器诊断结果的自适应融合,从而为最终故障判别提供统一决策输出。

$$\mathcal{L}_{\text{Time-PCL}} =$$

$$- \log \frac{\sum_{\tilde{P} \in \mathcal{P}_k^+} \exp(\text{sim}_{\cos}(T_i, \tilde{P}))}{\sum_{\tilde{P} \in \mathcal{P}_k^+} \exp(\text{sim}_{\cos}(T_i, \tilde{P})) + \sum_{\tilde{P} \in \mathcal{P}_k^-} \exp(\text{sim}_{\cos}(T_i, \tilde{P}))/N_k} \quad (13)$$

式中: $\mathcal{P}_k^+$ 为第 k 类的目标原型集合; $\mathcal{P}_k^-$ 为除第 k 类之外的非目标原型集合。

考虑到部分机械故障在时域波形上存在相似性,仅利用时间域约束难以充分表征其频谱差异。因此,进一步在频率域构建原型对比机制,以增强模型对特征频带分布及谐波结构差异的感知能力。

对时间域特征 $T_i \in \mathbb{R}^d$ 进行快速傅里叶变换

1.4 时间-频率原型对比学习小样本训练

在强噪声复杂工况下,高压断路器机械故障样本获取困难,训练数据通常具有样本量少、类别分布不均衡等特点。在此条件下,仅依赖交叉熵损失函数进行监督训练,难以充分约束特征空间分布,易导致同类样本聚集性不足和不同类别间边界模糊。

为此,本文在多源时频特征融合基础上引入时间-频率原型对比学习(TF-PCL)策略^[24]。该策略分别在时间域与频率域构建类别原型,通过样本与原型之间的对比,约束优化特征分布,提高小样本条件下的类别可分性。

设经过多级传感器融合网络与共享特征提取器后,第 i 个样本在时域的特征表示为 $T_i \in \mathbb{R}^d$,其中 d 表示特征维度。基于高置信样本集与查询样本集,分别计算每一类别的时间域原型向量 $\tilde{P}_c^{\text{time}}$,表达式为

$$\tilde{P}_c^{\text{time}} = \frac{1}{N_c} \sum_{i \in \mathcal{C}_c} T_i, c = 1, 2, \dots, C \quad (11)$$

式中: c 为故障类别索引; C 为故障类别总数; $\mathcal{C}_c$ 为第 c 类样本集合; N_c 为该类别样本数量。

为度量样本特征与原型之间的相似性,本文采用余弦相似度函数^[25] $\text{sim}_{\cos}(T_i, \tilde{P})$,表达式为

$$\text{sim}_{\cos}(T_i, \tilde{P}_c^{\text{time}}) = \frac{(T_i)^T \tilde{P}_c^{\text{time}}}{\|T_i\|_2 \|\tilde{P}_c^{\text{time}}\|_2} \quad (12)$$

式中: $T_i \in \mathbb{R}^d$ 为第 i 个样本的时间域特征向量; $\tilde{P}_c^{\text{time}}$ 为第 c 类的时间域原型向量; $(\cdot)^T$ 表示向量转置; $\|\cdot\|_2$ 为向量的 L_2 范数。

在此基础上,构建时间域原型对比损失函数^[26] $\mathcal{L}_{\text{Time-PCL}}$,表达式为

$$\mathcal{L}_{\text{Time-PCL}} =$$

$$- \log \frac{\sum_{\tilde{P} \in \mathcal{P}_k^+} \exp(\text{sim}_{\cos}(T_i, \tilde{P}))}{\sum_{\tilde{P} \in \mathcal{P}_k^+} \exp(\text{sim}_{\cos}(T_i, \tilde{P})) + \sum_{\tilde{P} \in \mathcal{P}_k^-} \exp(\text{sim}_{\cos}(T_i, \tilde{P}))/N_k} \quad (13)$$

(FFT)^[27],得到对应的频域特征 F_i 表达式为

$$F_i = f_{\text{FFT}}(T_i) \quad (14)$$

式中: $f_{\text{FFT}}(\cdot)$ 表示快速傅里叶变换。

类似地,构建频率域类别原型向量 $\tilde{P}_k^{\text{freq}}$,并采用与时间域一致的相似性度量与对比形式,得到频率域原型对比损失函数 $\mathcal{L}_{\text{Freq-PCL}}$:

$$\mathcal{L}_{\text{Freq-PCL}} = -\log \frac{\sum_{\tilde{P} \in \tilde{P}_k^{\text{freq}}} \exp(\text{sim}_{\cos}(F_i, \tilde{P}))}{\sum_{\tilde{P} \in \tilde{P}_k^{\text{freq}}} \exp(\text{sim}_{\cos}(F_i, \tilde{P})) + \sum_{\tilde{P} \in \tilde{P}_k^{\text{freq}}} \exp(\text{sim}_{\cos}(F_i, \tilde{P}))/N_k} \quad (15)$$

频率域约束主要作用于故障特征频率及能量分布结构的区分,与时间域原型约束形成互补,共同优化特征空间分布。

在原型对比学习约束之外,本文仍保留交叉熵损失函数以保证模型具备基本的判别学习能力,计算过程如式(10)。最终,总体优化目标函数 $\mathcal{L}_{\text{total}}$ 的表达式为

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{CE}} + \lambda \mathcal{L}_{\text{Time-PCL}} + \eta \mathcal{L}_{\text{Freq-PCL}} \quad (16)$$

式中: λ, η 分别为权重系数,用于平衡时间域与频率域原型对比约束的影响。

2 高压断路器机械故障诊断流程

本文提出的高压断路器机械故障诊断流程如图3所示,主要包括数据获取与预处理、多级融合特征建模、小样本模型训练以及故障状态判别这4个环节。

(1)多源机械状态信号的获取与预处理。通过多传感器同步采集高压断路器运行过程中的机械状态信号,包括多测点振动信号、触头行程及分合闸线圈电流等关键过程量,并完成时间对齐和归一化处理,为后续模型提供统一输入。

(2)多级传感器融合诊断网络构建。构建由数据级、特征级和决策级组成的多级融合网络。数据级完成多通道同构传感器信号的融合,特征级利用小波卷积提取多源时频特征,决策级依据各传感器输出的不确定性实现自适应融合,并获得最终融合诊断结果。

(3)面向小样本条件的模型训练。在网络训练阶段引入时间-频率原型对比学习策略,与交叉熵损失函数联合优化模型参数,增强小样本条件下特征空间的类别可分性。

(4)基于多级融合网络的机械故障诊断。将待测样本输入训练完成的诊断模型,输出高压断路器运行状态及对应的故障类别,从而实现正常状态和典型机械故障的识别。

3 案例分析

3.1 高压断路器机械故障诊断样本库的构建

为验证所提方法的机械故障诊断性能,本文构




图3 高压断路器机械故障诊断流程

Fig. 3 Mechanical fault diagnosis process of high-voltage circuit breakers

建了包含不同电压等级高压断路器的多源机械故障样本库。选取 VS1-ZN63A 型 10 kV 真空断路器作为源域对象,搭建高压断路器机械故障模拟与多源信号采集平台,其结构如图4所示。

在振动信号采集方面,选用 CT1000L 型压电式加速度传感器,分别布置于操动机构关键受力部位,并在 x, y, z 这 3 个方向进行同步测量,以全面捕

捉机械冲击与结构振动特性;线圈电流与触头位移信号通过机械特性测试仪同步获取,从电磁驱动与机械执行两个层面刻画断路器的动作过程。所有信号采用统一触发方式采集,并完成时间对齐和归一化处理,为后续融合建模提供统一输入。



图4 VS1-ZN63A型高压断路器故障模拟系统

Fig. 4 VS1-ZN63A high voltage circuit breaker fault simulation system

综合考虑高压断路器的典型机械失效模式及实验可实现性,源域设置正常状态及4类典型机械故障工况,包括:①传动连杆松动;②铁芯卡涩;③操作电压偏低;④操作电压偏高。通过对机构参数和供电条件的可控调节,实现各类故障稳定复现。每类工况采集250组同步样本,共同构成源域数据集。

考虑到实际工程中高电压等级断路器运行环境复杂、故障样本获取困难,本文选取252 kV SF₆断路器作为目标域对象,构建小样本条件下的多源机械故障样本库,其实验系统如图5所示。目标域采集的信号类型与源域保持一致,包括三向振动加速度、分合闸线圈电流及动触头位移行程信号,以保证不同电压等级数据具有一致的特征表达。

在目标域实验中,同样设置正常状态及与源域一致的4类典型机械故障工况。其中,故障1为传动连杆松动故障;故障2为铁芯卡涩故障;故障3为操作电压偏低故障;故障4为操作电压偏高故障。受限于高压等级设备的安全性与实验条件,每类工况采集50组同步样本,形成目标域小样本数据集。各类工况下的振动信号波形示例如图6所示。




(a) 断路器机构正面


(b) 断路器机构背面

图5 252 kV SF₆断路器故障模拟系统

Fig. 5 Fault simulation system of the 252 kV SF₆ circuit breaker



(a) 正常状态



(b) 故障1




图6 各类工况下振动信号波形

Fig. 6 Vibration signal waveforms under various working conditions

3.2 实验结果与分析

本文所有实验均在同一计算平台完成,以保证

结果的公平性与可复现性。实验硬件配置为 Intel (R) Core (TM) i9-14900K 处理器、NVIDIA GeForce RTX 5090 以及 64 GB 内存,软件环境为 Python 3.13.9、PyTorch2.9.1 和 CUDA12.8。模型采用 Adam 优化器训练,初始学习率为 1×10^{-4} ,批量数为 32,训练轮数为 50。网络参数采用 Glorot 正态分布初始化,并结合学习率衰减策略提高收敛稳定性。上述参数均通过预实验确定,并在所有对比实验中保持一致。模型性能采用精确率、召回率和 F1 值进行评价,其中 F1 值能够综合反映模型在小样本条件下的分类性能。

首先,为验证多传感器融合的有效性,本文对单一传感器输入与多传感器融合输入进行了对比,结果如表 1 所示。由表 1 可知,多传感器融合条件下模型在精确率、召回率及 F1 值上均明显优于任一单一传感器输入。其主要原因在于不同传感器对高压断路器机械振动的响应机理和敏感频段存在差异,多源信号在时域、频域及时频域层面具有显著互补性。多级融合网络通过对多源特征进行协同建模,有效缓解了单一传感器在局部工况或强噪声条件下信息不足的问题,从而提升了诊断结果的稳定性与一致性。

表 1 单一传感器与多传感器融合条件下的诊断结果

Table 1 Diagnosis results under single-sensor and multi-sensor inputs

传感器输入	精确率/%	召回率/%	F1/%
分合闸线圈电流	91.42	89.36	90.37
触头行程	92.05	90.11	91.07
振动	92.86	90.94	91.89
多传感器融合输入	99.06	98.87	97.93

在此基础上,为比较不同融合方式的性能,本文分别构建数据级融合、特征级融合、决策级融合及 Dempster-Shafer(DS)证据理论融合模型。各融合策略均基于相同的多传感器输入与网络规模,仅在融合层级与融合方式上进行差异化设计,以保证对比结果的公平性,实验结果如表 2 所示。

由表 2 可知,特征级和决策级融合均优于数据级融合。其中,与性能最优的特征级融合策略相比,本文策略的精确率、召回率和 F1 值分别提高了 2.58%、4.85% 和 2.70%;相比数据级融合方法,以上 3 项指标分别提高了 5.94%、8.03% 和 5.97%。数据级融合能够保留较完整的原始信息,但容易受

表2 不同融合策略下的诊断性能对比

Table 2 Diagnostic performance comparison of different fusion strategies

融合策略	精确率/%	召回率/%	F1/%
数据级	93.12	90.84	91.96
特征级	96.48	94.02	95.23
决策级	95.67	93.54	94.59
DS	94.81	92.36	93.57
本文策略	99.06	98.87	97.93

到噪声干扰;特征级融合进一步挖掘不同传感器之间的互补关系,具有更好的特征表达能力;决策级融合能够降低单一传感器误判带来的影响。相比之下,本文策略通过数据级、特征级和决策级的协同融合,实现了多源信息的优势互补,在3项评价指标上均取得最佳结果。

在此基础上,将本文模型与多种典型机械故障诊断及小样本学习模型进行对比,包括:卷积神经网络(CNN)、傅里叶特征重构网络(FFRN)、域适应迁移学习(DATL)、特征融合度量学习(FFMN)以及对比学习方法(CL)。整体诊断结果如表3所示。由表3可知,CNN和FFRN由于缺乏对小样本及复杂工况的适应能力,诊断性能较低;DATL、FFMN和CL通过迁移学习或对比学习提高了模型性能,但仍未充分利用多源传感信息。相比之下,本文模型的精确率、召回率和F1值分别提高了6.52%、9.24%和6.87%,说明多级融合策略结合小波卷积和原型对比学习能够有效提升故障特征的判别能力。

表3 不同模型的高压断路器机械故障诊断结果

Table 3 Fault diagnosis results of high-voltage circuit breakers using different models

模型	精确率/%	召回率/%	F1/%
CNN	30.54	30.25	29.85
FFRN	35.63	32.35	31.58
DATL	86.57	83.26	84.15
FFMN	92.36	90.59	91.23
CL	89.95	89.67	85.69
本文模型	99.06	98.87	97.93

考虑到现场运行环境中,振动信号不可避免受到强背景噪声的干扰,本文进一步分析了不同信噪比条件下,各模型的诊断性能变化情况,结果如图7所示。需要说明的是,受实验条件限制,本文未在机械故障模拟平台中额外构建独立噪声源系统。

为模拟现场运行过程中电磁干扰、环境振动及随机测量噪声等因素对监测信号的影响,本文在实测获取的多源信号基础上叠加不同强度的高斯白噪声,构建不同信噪比条件下的测试数据集。该方法已广泛应用于故障诊断与信号处理领域的抗噪性能评估,能够在可控条件下客观评价模型对噪声扰动的鲁棒性。除表2所列策略外,本文进一步补充了以下具有代表性的对比模型:①传统卷积多传感器模型(Conv-MS),在网络结构和多传感器输入方式保持一致的前提下,用标准卷积算子替代本文的小波卷积模块,用以验证小波卷积在强噪声环境下的优势;②单传感器小波卷积模型(Wavelet-SS),仅使用单一传感器信号输入,用于分析多传感器融合对抗噪性能的贡献;③单传感器传统卷积模型(Conv-SS),作为基线模型,评估在强噪声条件下单一传感器与传统卷积结构的性能下限。

由图7可知,在实测信号叠加不同强度随机噪声后,随着信噪比的降低,各对比模型的诊断性能均呈现不同程度的下降,但下降幅度存在显著差异。其中,基于传统卷积的模型在-5dB时,F1值下降了约10%,在-15dB条件下性能劣化更为明显;而本文模型在-15dB条件下F1值仍保持在90%以上,相比传统卷积模型提升接近15%,表明所构建的多级传感器融合网络对强背景噪声具有更强的抑制能力。究其根本原因在于小波卷积在多尺度下对瞬态冲击特征具有更好的时频定位能力,能够有效削弱噪声对关键故障特征的掩盖作用;同时,多传感器信息的协同融合进一步提升了故障表征的一致性与鲁棒性。

为直观分析不同小样本方法在特征空间中的




图7 不同信噪比条件下各模型的F1值

Fig. 7 F1-score under different signal-to-noise ratio conditions

判别能力,对正常状态以及4类机械故障状态提取的特征进行了t-SNE二维可视化,结果如图8所示。可以看出,引入时间-频率原型对比损失函数后,同类样本在特征空间中聚类更加紧凑,不同类别之间的边界更加清晰;而传统小样本方法在部分类别上仍存在明显的类间混叠现象。该结果表明,通过在时频空间中引入原型级对比约束,有助于缓解小样本条件下类内离散和类间重叠问题,从而提升特征判别性与泛化能力。




图8 不同模型的二维特征可视化结果

Fig. 8 Two-dimensional feature visualization results of different models

为验证多级融合网络中各关键模块的有效性,本文设计了多组消融实验,包括:去除多传感器融合模型(CDAN)、以传统卷积替代小波卷积的模型(PCCDAN)以及采用传统对比策略替代原型对比机制的模型(CFDA)。所有消融实验均在相同的数据划分、网络规模与训练参数条件下进行,以保证对比结果的公平性,实验结果如表4所示。由表可知,删除任一模块后模型性能均有所下降。其中,PCCDAN下降最明显,说明小波卷积对抗噪特征提取具有重要作用;CCDA性能下降表明原型对比学习能够提高类别区分能力;CDAN则说明多传感器融合有助于充分利用不同传感器的互补信息。完整模型获得最佳诊断结果,验证了各模块的协同作用。

从可解释性角度分析,通过改进的梯度加权类

表4 消融实验结果对比

Table 4 Ablation experiment comparison results

模型	精确率/%	召回率/%	F1/%
CDAN	90.67	88.17	89.05
PCCDAN	95.29	91.45	93.33
CCDA	92.54	89.63	91.06
完整模型	99.06	98.87	97.93

激活映射方法 Grad-CAM++ 得到的可视化结果如图9所示。由图9可知,不同故障类型对应的时频关注区域具有明显差异:正常状态下特征响应分布较为均匀,反映系统运行的稳定性;传动连杆松动故障对应较为明显的局部冲击特征;铁芯卡涩故障对应的模型关注区域主要集中于低频及能量突变区域;而不同电压工况下的故障在高、低频能量分布上呈现出差异化特征。上述结果表明,模型关注的关键时频区域与已知机械激励与响应机理保持一致,增强了诊断结果在强噪声与小样本条件下的物理一致性与可信度。




图9 Grad-CAM++的可视化结果

Fig. 9 Grad-CAM++ visualization of salient feature regions

4 结 论

针对强噪声环境下,高压断路器机械故障诊断背景噪声干扰强、多源信息利用不足及小样本条件下特征判别能力下降的问题,本文提出了一种基于多级传感器融合网络的机械故障诊断方法,并基于自主搭建的机械故障试验平台进行了验证。得到以下主要结论。

(1) 本文从多源响应机理出发,构建了数据级、特征级和决策级协同融合的多级传感器融合框架,实现了多源监测信息的有效融合。实验结果表明:与性能最优的特征级融合策略相比,本文策略的精

确率、召回率和F1值分别提高了2.58%、4.85%和2.70%;相比数据级融合方法,以上3项指标分别提高了5.94%、8.03%和5.97%,这说明多级融合能够进一步提升高压断路器机械故障诊断性能。

(2)采用小波卷积特征建模机制进行多尺度时频特征提取,提高了模型对强背景噪声的适应能力。不同信噪比条件下的实验结果表明,在-15 dB条件下模型F1值仍保持在90%以上,较传统卷积模型具有更好的抗噪性能,从而验证了小波卷积在复杂噪声环境下提取机械故障特征的有效性。

(3)引入时间-频率原型对比学习策略,改善了小样本条件下特征分布类内离散与类间混叠的问题。与传统对比学习模型相比,本文模型的精确率、召回率和F1值分别提高了6.52%、9.24%和6.87%。Grad-CAM++可视化结果进一步表明,模型关注区域与机械激励-响应特征具有较好的一致性,增强了诊断结果的可解释性。

参考文献:

- [1] Zhang Z, Wang Y, Yan J, et al. Multi-Information Fusion Diagnosis of High-Voltage Circuit Breakers via Newton - Raphson Optimised Transformer and Meta-Transfer Learning[J]. IET Generation, Transmission & Distribution, 2026, 20(1): e70252.
- [2] 赵陈琛,张国钢,刘洁,等. 基于物理信息和迁移网络的高压断路器弹簧操动机构机械参数辨识及故障诊断[J/OL]. 电工技术学报,1-13[2025-08-01].
Zhao Chenchun, Zhang Guogang, Liu Jie, et al. Mechanical parameter identification and fault diagnosis of spring operating mechanism of high-voltage circuit breaker based on physical information and transfer network [J/OL]. Transactions of China Electrotechnical Society, 2025.
- [3] 范兴明,许洪华,张思舜,等. 基于改进蜣螂优化算法深度混合核极限学习机的高压断路器故障诊断[J]. 电工技术学报,2025,40(12):3994-4003.
Fan Xing ming, Xu Honghua, Zhang Sishun, et al. Fault diagnosis of high voltage circuit breaker based on improved dung beetle optimizer algorithm deep hybrid kernel extreme learning machine [J]. Transactions of China Electrotechnical Society, 2025, 40(12): 3994-4003.
- [4] 范兴明,许洪华,张思舜,等. 基于IDBO-DHKELM的高压断路器故障诊断研究[J/OL]. 电工技术学报,1-12[2025-08-01].
Fan Xing ming, Xu Honghua, Zhang Sishun, et al. Research on fault diagnosis of high voltage circuit breaker based on IDBO-DHKELM [J/OL]. Transactions of China Electrotechnical Society, 2025.
- [5] 王艳新,闫静,荆乾震,等. 基于先验知识约束和对比域适应学习的高压断路器机械故障诊断方法研究[J]. 电工技术学报, 1-13[2025-10-30].
Wang Yanxin, Yan Jing, Jing Qianzhen, et al. Mechanical fault diagnosis of high-voltage circuit breakers based on prior knowledge constraints and contrastive domain adaptation [J/OL]. Transactions of China Electrotechnical Society, 2025.
- [6] Wang Y, Yan J, Zhang Z, et al. Few-Shot Mechanical Fault Diagnosis of High-Voltage Circuit Breakers Using Prior Knowledge-Constrained Wavelet-Based Multi-Frequency Feature Fusion [C]//2025 IEEE China International Youth Conference on Electrical Engineering (CIYCEE). IEEE, 2025: 1-7.
- [7] Song Q, Wang J, Song Q, et al. Fault Diagnosis for the Operating Mechanism of High-Voltage Circuit Breakers using Multi-Channel Fusion Convolutional Neural Network[J]. 2024.
- [8] Ye X, Yan J, Wang Y, et al. A novel circuit breaker fault diagnosis method based on dense residual and attention mechanism [J]. IET Generation, Transmission & Distribution, 2023, 17(19): 4316-4328.
- [9] Wang Yanxin, Yan Jing, Wang Jianhua, et al. A novel hybrid transfer learning approach for small-sample high-voltage circuit breaker fault diagnosis on-site[J]. IEEE Transactions on Industry Applications, 2023, 59(4): 4942-4950.
- [10] Wang Yanxin, Yan Jing, Ye Xinyu, et al. Few-shot transfer learning with attention mechanism for high-voltage circuit breaker fault diagnosis [J]. IEEE Transactions on Industry Applications, 2022, 58(3): 3353-3360.
- [11] Shao Y, Zhang Z, Wu J, et al. Multi-Sensor Sensitivity Assessment Strategy for High-Voltage Circuit Breaker Fault Diagnosis Using GA-SoftMax Model [J]. IEEE Transactions on Power Delivery, 2025.
- [12] 张国宝,王朝廷,黄伟民,等. 基于多源传感器数据融合的断路器故障诊断方法[J]. 高电压技术,2025,51(02): 660-668.
Zhang Guobao, Wang Zhaoyan, Huang Weimin, et al. Fault Diagnosis Method of Circuit Breaker Based on Multi-source Sensor Data Fusion [J]. High Voltage Engineering, 2025, 51(02): 660-668.

- [13] Wang Y, Yan J, Qi M, et al. A Novel Meta-Learning and Network Architecture Search Approach for Few-Shot High-Voltage Circuit Breaker Fault Diagnosis [C]//2023 IEEE 6th International Electrical and Energy Conference (CIEEC). IEEE, 2023: 122-127.
- [14] 张瑞霖,张悦,孙晓兰,等. 基于可变形卷积与自监督对比学习的GIS局部放电诊断方法[J]. 高电压技术, 2024, 50 (11): 5022-5033.
- Zhang Ruilin, Zhang Yue, Sun Xiaolan, et al. GIS partial discharge diagnosis method based on deformable convolution and self-supervised contrastive learning [J]. High Voltage Engineering, 2024, 50 (11): 5022-5033.
- [15] 杨夏洁,林子谦,徐丹丹,等. 基于联邦对比学习的航天器故障诊断研究[J/OL]. 计算机应用研究, 1-8 [2025-08-01].
- Yang Xiajie, Lin Ziqian, Xu Dandan, et al. Study of spacecraft fault diagnosis based on federated comparative learning[J/OL]. Application Research of Computers, 2025.
- [16] 张珂,郑朝烨,石超君,等. 基于多模态对比学习的输电线路螺栓缺陷分类[J]. 高电压技术, 2025, 51(02): 630-641.
- Zhang Ke, Zhe Chaoye, Shi Chaojun, et al. Transmission line bolt defects classification based on multi-modal contrastive learning [J]. High Voltage Engineering, 2025, 51 (02): 630-641.
- [17] Yan J, Wang Y, Yang Z, et al. Few-shot mechanical fault diagnosis for a high-voltage circuit breaker via a transformer - convolutional neural network and metric meta-learning [J]. IEEE Transactions on instrumentation and measurement, 2023, 72: 1-11.
- [18] Yang Chaoying, Liu Jie, Xu Qi, et al. A generalized graph contrastive learning framework for few-shot machine fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2023, 20(2): 2692-2701.
- [19] Miao Y, Wang J, Zhang B, et al. Practical framework of Gini index in the application of machinery fault feature extraction[J]. Mechanical Systems and Signal Processing, 2022, 165: 108333.
- [20] Chen Z, Yang Y, He C, et al. Feature extraction based on hierarchical improved envelope spectrum entropy for rolling bearing fault diagnosis [J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-12.
- [21] Fan C, Yun M, Chen L, et al. DWMFusion: A lightweight medical image fusion network based on discrete wavelet convolution and selective state space models[J]. Expert Systems with Applications, 2025, 286: 128040.
- [22] Xiao X, Li C, He H, et al. Rotating machinery fault diagnosis method based on multi-level fusion framework of multi-sensor information[J]. Information Fusion, 2025, 113: 102621.
- [23] Wang Y, Yan J, Yang Z, et al. A domain adaptive deep transfer learning method for gas-insulated switchgear partial discharge diagnosis [J]. IEEE Transactions on Power Delivery, 2021, 37(4): 2514-2523.
- [24] Dong Y, Jiang H, Wang X, et al. An interpretable integration fusion time-frequency prototype contrastive learning for machine fault diagnosis with limited labeled samples[J]. Information Fusion, 2025, 124: 103340.
- [25] Bettahar T, Rahmoune C, Benazzouz D, et al. New method for gear fault diagnosis using empirical wavelet transform, Hilbert transform, and cosine similarity metric [J]. Advances in Mechanical Engineering, 2020, 12(6): 1687814020927208.
- [26] Wang Y, Yan J, Zhang Z, et al. A novel multi-sensor fusion method for diagnosing insulation defects in gas-insulated substations guided by adaptive-attention and contrastive-based few-shot learning[J]. Applied Soft Computing, 2026: 114600.
- [27] Rathore A, Gupta P, Sharma R, et al. Day ahead solar forecast using long short term memory network augmented with Fast Fourier transform-assisted decomposition technique [J]. Renewable Energy, 2025, 247: 123021.

(编辑 刘懿莹)