

DOI: 10.19650/j.cnki.cjsi.J2514763

# 基于 ISGMD 与深度学习的万能式断路器 机械特性参数测量\*

孙曙光<sup>1</sup>, 赵恩泽<sup>1</sup>, 胡雨辰<sup>2</sup>, 王景芹<sup>3</sup>, 崔玉龙<sup>4</sup>

(1. 河北工业大学人工智能与数据科学学院 天津 300130; 2. 中国铁路设计集团有限公司 天津 300142; 3. 河北工业大学智能配用电装备与系统全国重点实验室 天津 300130; 4. 北京化工大学信息科学与技术学院 北京 100029)

**摘要:**针对声音信号在万能式断路器机械状态监测中存在模态分解需人工设定参数、可解释性差以及短时分析法适用性有限的问题,提出了一种结合改进辛几何模态分解(ISGMD)和时频注意力机制(TFA)的声音事件检测模型。该方法通过同步采集断路器动作过程中的声音信号、主轴角位移及触头电压信号,对合分闸事件进行时频关联分析;利用ISGMD对声音信号进行自适应分解,克服无效分量干扰以及物理意义不明确的局限,再经S变换构建时频图,凸显信号时频分布规律,以此构建后续模型训练所需的数据集;最后,通过构建深度学习网络,在特征提取部分嵌入时频注意力机制,使网络能够动态聚焦于与合分闸事件相关的频率区间,结合双向长短期记忆网络(Bi-LSTM)深入挖掘声音事件前后序列中的长时依赖关系,从而实现事件边界的准确定位,有效降低误判与漏判概率。结果表明:所提方法识别准确率、召回率及F1分数均达93%左右;对不同传声器位置与距离的数据,测量均方根误差(RMSE) $< 0.44$  ms;对于不同设备的RMSE $< 0.57$  ms,展示出良好的泛化能力与稳定性。ISGMD从物理机理层面提供可解释的信号分解,深度学习则从数据层面驱动复杂事件特征的自动学习。两者协同构成的方法实现了声音事件毫秒级定位,为断路器机械状态智能诊断提供了可靠支撑。

**关键词:** 断路器;机械特性;辛几何模态分解;深度学习;声音事件检测

**中图分类号:** TM561 TH165.3 **文献标识码:** A **国家标准学科分类代码:** 470.40

## Measurement of circuit breaker mechanical characteristic parameters based on ISGMD and deep learning

Sun Shuguang<sup>1</sup>, Zhao Enze<sup>1</sup>, Hu Yuchen<sup>2</sup>, Wang Jingqin<sup>3</sup>, Cui Yulong<sup>4</sup>

(1. School of Artificial Intelligence and Data Science, Hebei University of Technology, Tianjin 300130, China;

2. China Railway Design Co., Ltd., Tianjin 300142, China; 3. National Key Laboratory of Intelligent

Power Distribution and Utilization Equipment and Systems, Hebei University of Technology, Tianjin 300130, China;

4. College of Information Science and Technology, Beijing University of Chemical Technology, Beijing 100029, China)

**Abstract:** To address the issues in the mechanical condition monitoring of air circuit breakers using acoustic signals—specifically, the dependence on manual parameter setting and poor interpretability of modal decomposition methods, as well as the limited applicability of short-time analysis techniques—this paper proposes a sound event detection model combining improved symplectic geometric mode decomposition (ISGMD) and a time-frequency attention (TFA) mechanism. The method involves synchronously collecting acoustic signals, main shaft angular displacement, and contact voltage signals during circuit breaker operation to perform time-frequency correlation analysis on closing/opening events. ISGMD is utilized to adaptively decompose the acoustic signals, overcoming interference from invalid components and the limitation of unclear physical meaning. Subsequently, S-transform is applied to construct time-frequency spectrograms, highlighting the time-frequency distribution patterns of the signals and thereby building the dataset required for subsequent model training. Finally, a deep learning network is constructed by embedding the time-frequency attention mechanism into the feature extraction module. This enables the network to dynamically focus on frequency intervals associated with the closing/opening events.

收稿日期: 2025-12-11 Received Date: 2025-12-11

\* 基金项目: 河北省中央引导地方科技发展资金(246Z2101G)、河北省教育厅科学研究(CXZX2026047)项目资助

Combined with the bidirectional long short-term memory (Bi-LSTM) network to deeply explore long-term dependencies in the sequences before and after sound events, the model achieves accurate localization of the boundaries of closing/opening events, effectively reducing the probabilities of false alarms and missed detections. The results indicate that the proposed method achieves an accuracy, recall, and F1-score of approximately 93%. For data from different microphone positions and distances, the root mean square error (RMSE) is less than 0.44 ms; for different devices, the RMSE is below 0.57 ms, demonstrating good generalization capability and stability. ISGMD provides interpretable signal decomposition from the perspective of physical mechanisms, while deep learning drives the automatic learning of complex event features from the data level. The synergistic approach formed by these two approaches achieves millisecond-level localization of sound events, providing reliable support for the intelligent diagnosis of the mechanical condition of circuit breakers.

**Keywords:** circuit breaker; mechanical characteristics; symplectic geometry mode decomposition; deep learning; sound event detection

## 0 引言

万能式断路器作为低压配电系统的核心保护设备,承担着电能分配与线路保护的关键职责,其机械特性参数直接决定了设备的开断性能与配电系统可靠性<sup>[1]</sup>。随着《“十四五”现代能源体系规划》的深入推进,电力系统智能化升级对设备状态监测提出了更高要求<sup>[2]</sup>。通过特性参数测量,可以更好地了解断路器内部操作机构及触头系统运动状态,对其机械状态进行定量评估可以优化配电系统的维护和管理,并依此制定相应的维护计划,以最大程度地延长设备的使用寿命。

机械特性检测是电力设备运检的重要内容,相关研究逐渐成为热点。目前断路器的机械特性监测主要依赖振动<sup>[3-4]</sup>、线圈电流<sup>[5-6]</sup>及位移信号<sup>[7-9]</sup>等接触式测量手段。尽管振动信号可有效表征机械状态,但对传感器安装位置和方式要求较高。位移信号与线圈电流虽能反映主轴运动信息及操作机构动作状态,却难以反映触头系统和弹簧机构的动态特性。触头电压信号能够直接反映触头接触状态,但需要在主回路中增设传感器,显著增加了检测风险和测量复杂度。除此之外,传统测量方法普遍需拆解设备,存在操作复杂、停电时间长、改变设备原始状态甚至加速绝缘老化等问题,难以满足新型电力设备对无损化、在线化与智能化监测的迫切需求。

在此背景下,非接触测量技术因其免拆卸、无干预的特性成为研究热点<sup>[10-13]</sup>。高速摄像机虽能直观记录,但图像处理算法复杂,且对拍摄角度要求较为苛刻;激光位移传感器虽精度高,但仅能进行单点测量,并对传感器安装位置要求较高,轻微偏移可能导致测量数据失效。相比之下,声音信号与振动信号来源相同,蕴含丰富的机构运动信息,同时因其获取方式相对便利,且测点位置少量偏离对声音信号的响应差异较小,为机械特性参数的在线提取提供了独特优势<sup>[14]</sup>。断路器合分闸过程中的时间参数是评估其机械性能的关键指标,对动作过程中的瞬态事件定位是计算断路器运动时间参数的关键工作。

相关研究表明断路器动作过程信号的频率、能量等特性与其内部机构运动中关键事件之间存在联系。李辰辉等<sup>[15]</sup>证实了断路器触头刚合事件与振动高频特征时刻的强相关性,实现了触头系统刚合点的精确定位。孙曙光等<sup>[16]</sup>通过识别触头碰撞激发的短时宽频带振动信号特征,成功确定了主触头碰撞的关键事件节点。根据断路器弹簧操作机构的工作原理,万书亭等<sup>[17]</sup>分析了合闸运动过程各个部件机械冲击产生的振动特性,并进一步利用时域分析方法,实现对断路器合闸过程中时间参数的提取。以上研究共同验证了基于信号特征识别断路器关键运动事件、划分动作阶段,并最终实现运动时间参数测量的可行性。

然而,断路器机械状态的非接触声学监测技术面临多重挑战:1)瞬态冲击事件持续时间短、能量分布不均,易被长时宽频噪声淹没;2)断路器动作过程中声音信号频谱演化规律尚未完全明确,现有滤波处理可能因经验性取舍造成有效分量的不可逆损失;3)时域分析因其静态阈值设定导致对弱冲击事件误判率高,常规时频分析方法受制于 Heisenberg 不确定性原理,难以兼顾瞬态事件的高精度定位与特征频率的准确提取。

针对上述挑战,现有研究主要通过信号分解与特征优化两条路径寻求突破:部分学者采用自适应分解方法,通过模态筛选提升特征可分离性。王鸣等<sup>[18]</sup>利用经验模态分解(ensemble mode decomposition, EMD)提升弱振动事件边界清晰度,但存在模态混叠的固有缺陷。孙玉伟等<sup>[19]</sup>使用的变分模态分解(variational mode decomposition, VMD)需预设模态数,难以适配断路器动作过程中随机性强的瞬态信号,且计算复杂度显著增加。辛几何模态分解(symplectic geometry mode decomposition, SGMD)作为非线性信号处理的新兴方法,其核心优势在于通过相空间重构保留信号的结构特性与时序完整性,实现高保真度的模态分解<sup>[20]</sup>,近年来在轴承状态监测、电能质量分析等领域展现出显著优势。陈志刚等<sup>[21]</sup>采用 SGMD 分解电机轴承振动信号,结合改进凝聚层次聚类算法筛选辛几何分量,有效提升了故障识别率。郭成

等<sup>[22]</sup>将其应用于同步振荡电流信号分析,并引入动态时间规整(dynamic time warping, DTW)优化分量筛选过程。

对于特征优化,为克服时域分析法阈值不能动态调整的问题,可考虑使用深度学习对事件进行识别。声音事件检测(sound event detection, SED)旨在识别音频信号中的目标声音事件及其起止时间<sup>[23]</sup>。随着智能化检测的普及,SED 也可被应用在断路器机械状态监测任务中。针对深度学习模型直接处理一维声音信号存在计算冗余、时频特征捕捉不足的缺陷,考虑到 S 变换通过频率自适应高斯窗,实现时间分辨率与频率分辨率的动态平衡的优点,选择该方法将一维声音信号转为二维时频图,凸显信号的时频分布特性并提高后续模型计算效率。

然而,SGMD 方法存在共性瓶颈,分量筛选过程算法参数需人工预设,导致其泛化能力受限。卷积神经网络在 SED 任务中表现卓越<sup>[24]</sup>,但其中卷积神经网络(convolutional neural network, CNN)对时频区域缺乏动态感知能力,难以识别断路器声音信号中的瞬态机械碰撞,制约了边界定位精度。

针对上述分析,本文提出改进方法包括:

1) 提出改进辛几何模态分解方法(improved SGMD, ISGMD),采用参数自适应的基于密度的聚类算法(density-based spatial clustering of application with noise, DBSCAN),对分量进行聚类,剔除过分解信号,克服人工调参的依赖,并融合峭度与能量谱熵,构建筛选分量的综

合评价指标,用以筛选高冲击强度与窄带频谱特性的分量,显著提升瞬态事件分量的辨识度。

2) 在 CNN 中嵌入时频注意力机制(time-frequency attention, TFA),动态增强事件关联频带响应,提升对瞬态特征的感知能力,结合双向长短期记忆网络(bidirectional long short-term memory, Bi-LSTM)能同时利用历史与未来信息的优点,实现对断路器动作过程中的精确建模,通过全连接层输出各时间步的事件概率分布,将 SED 转化为时间步的事件多分类问题,有效避免短时分析法的误判与漏判。

以上方法,将 ISGMD、S 变换与 SED 网络联合,形成物理机理与数据驱动深度融合的检测框架。前部分保留冲击分量物理意义,后部分深度学习模型实现端到端的事件定位。

### 1 断路器动作时间参数测量方法

本文旨在通过上述创新方法,解决断路器声学监测中的瞬态事件捕捉、特征提取等关键问题,为实现断路器机械状态的非接触、高精度、智能化监测提供有效的技术手段。在断路器机械状态监测中,声音信号蕴含丰富的机构运动信息,但其非平稳特性与动作过程的随机性给时间参数的精确提取带来挑战。本文提出一种级联分析框架,流程如图 1 所示。

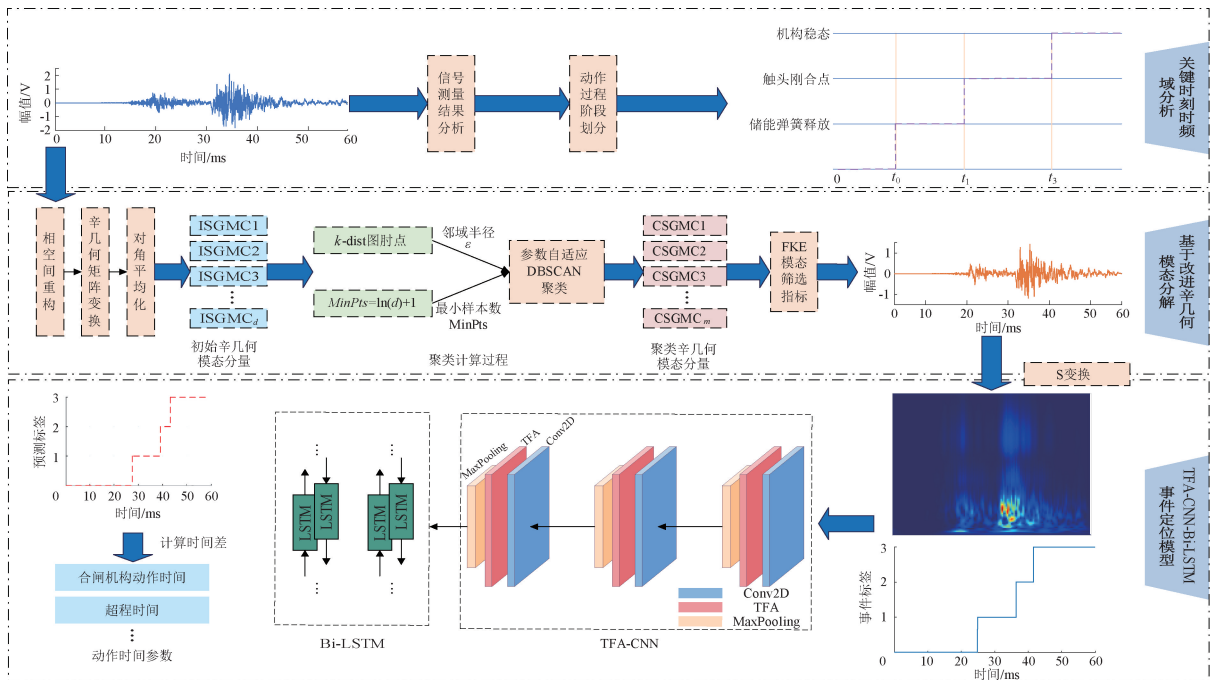


图 1 断路器动作过程声音事件检测整体流程

Fig. 1 Overall process of sound event detection in circuit breaker operation

首先采用 SGMD 将信号进行分解,其次使用参数自

适的 DBSCAN 算法以实现分量的有效聚类,该算法借

助  $k$ -距离图寻找最优邻域半径  $\varepsilon_{opt}$ , 并依据分量组数确定最小样本数。提出特征峭度谱熵 (feature kurtosis spectral entropy, FKE) 指标用于分量筛选, 然后借助 S 变换将信号转换为时频图以捕捉瞬态事件; 最后设计了一种 TFA 增强的 CNN-Bi-LSTM 网络, 通过卷积模块提取局部时频特征, 经 Bi-LSTM 建模时间依赖关系, 实现声音事件识别任务, 有效解决了传统方法中瞬态冲击丢失、时频分辨率不足以及事件边界误判的问题。

### 1.1 改进辛几何模态分解

SGMD 因其相空间重构特性, 被广泛应用在振动、声音信号等非平稳信号模态分解中, 且取得了良好效果。SGMD 方法的具体步骤包括:

#### 1) 相空间重构

设声音信号时间序列为  $x = x_1, x_2, \dots, x_n$ , 其中  $n$  为数据长度, 根据 Takens 嵌入定理, 通过对  $x$  进行重构可得到轨迹矩阵  $\mathbf{X}$ 。

$$\mathbf{X} = \begin{bmatrix} x_1 & x_{1+\tau} & \cdots & x_{1+(d-1)\tau} \\ \vdots & \vdots & \ddots & \vdots \\ x_m & x_{m+\tau} & \cdots & x_{m+(d-1)\tau} \end{bmatrix} \quad (1)$$

其中,  $m = n - (d - 1)\tau$ ,  $d$  为嵌入维数,  $\tau$  为延迟时间。

#### 2) 辛几何矩阵变换

对  $\mathbf{X}$  进行自相关分析得到协方差对称矩阵:  $\mathbf{A} = \mathbf{X}^T \mathbf{X}$ , 使用协方差矩阵构造 Hamilton 矩阵, 即:

$$\mathbf{M} = \begin{bmatrix} \mathbf{A} & \mathbf{0} \\ \mathbf{0} & -\mathbf{A}^T \end{bmatrix} \quad (2)$$

令  $\mathbf{N} = \mathbf{M}^2$ , 则矩阵  $\mathbf{N}$  也为 Hamilton 矩阵。因此, 通过式(3)可以构造出辛正交矩阵  $\mathbf{Q}$ , 即:

$$\mathbf{Q}^T \mathbf{N} \mathbf{Q} = \begin{bmatrix} \mathbf{B} & \mathbf{R} \\ \mathbf{0} & \mathbf{B}^T \end{bmatrix} \quad (3)$$

其中,  $\mathbf{R}$  为变换后的子矩阵,  $\mathbf{B}$  为上三角矩阵。令变换系数矩阵  $\mathbf{S}_i = \mathbf{Q}_i^T \mathbf{X}^T$ , 然后对  $\mathbf{S}_i$  进行变换, 即可得到初始单分量矩阵, 即:

$$\mathbf{Z}_i = \mathbf{Q}_i \mathbf{S}_i, \quad i = 1, 2, \dots, d \quad (4)$$

#### 3) 对角平均化

进一步对  $\mathbf{Z}_i$  进行对角平均化处理。矩阵  $\mathbf{Z}_i$  的各元素为  $z_{ij}$ , 其中  $1 \leq i \leq d, 1 \leq j \leq m$ 。令  $d^* = \min(m, d)$ ,  $m^* = \max(m, d)$ ,  $n = m + (d - 1)\tau$ 。式中当  $m < d$  时, 取  $z_{ij}^* = z_{ij}$ , 否则取  $z_{ij}^* = z_{ji}$ 。对角平均化转换矩阵如式(5)所示。

$$y_k = \begin{cases} \frac{1}{k} \sum_{p=1}^k z_{p,k-p+1}^*, & 1 \leq k < d^* \\ \frac{1}{d^*} \sum_{p=1}^{d^*} z_{p,k-p+1}^*, & d^* \leq k \leq m^* \\ \frac{1}{n-k+1} \sum_{p=k-m^*+1}^{n-m^*+1} z_{p,k-p+1}^*, & m^* < k \leq n \end{cases} \quad (5)$$

由此确定长度为  $n$  的一维时间序列  $y_1, y_2, \dots, y_n$ 。依次对矩阵  $\mathbf{Z}_i (1 \leq i \leq d)$  作此处理, 则可得到轨迹矩阵  $\mathbf{X}$  在时域内的  $d$  组独立分量。将其排列构建为矩阵  $\mathbf{Y}$ , 可得到初始辛几何模态分量 (initial symplectic geometric modal components, ISGMCs)。

$$\mathbf{Y} = \mathbf{Y}_1 + \mathbf{Y}_2 + \cdots + \mathbf{Y}_d \quad (6)$$

#### 4) 参数自适应 DBSCAN 聚类算法

原始声音信号经轨迹矩阵分解后产生  $d$  个 ISGMCs, 常因频率重叠导致特征冗余, 传统筛选方法对瞬态冲击成分的敏感性不足, 易遗漏关键信息。为此引入 DBSCAN 聚类算法, 通过自适应参数设计实现分量的高效聚类与冗余消除。

DBSCAN 核心思想是将高密度区域划分为簇, 滤除低密度区域的噪声点, 其密度驱动的自适应机制与 ISGMCs 频率特性高度适配。相比传统聚类方法, 该算法具有以下优势: 无需预先指定聚类数, 适应分量数量未知的场景; 通过优化邻域半径  $\varepsilon$  和最小样本数  $MinPts$  动态调整聚类粒度, 避免过分割或欠分割; 自动分离低密度点, 抑制异常值干扰。

该算法原理为: 以分量  $\mathbf{Y}_i$  为中心,  $\varepsilon$  为半径的超球区内域, 若样本数达到  $MinPts$ , 则  $\mathbf{Y}_i$  为核心对象, 可扩展成簇。该算法无需预先指定聚类数, 但需要设置邻域半径  $\varepsilon$  和最小样本数  $MinPts$ 。其中最小样本数  $MinPts$  随分量总数  $d$  动态调整, 即:

$$MinPts = \ln(d) + 1 \quad (7)$$

邻域半径  $\varepsilon$  通过  $k$ -dist 图曲率最大点, 即肘点确定, 该点对应数据密度的自然分界, 定量地定义了在一定范围内, 一个分量可以被认为是另一个分量的“邻居”。该过程将所有分量聚类为簇, 可避免人为参数设定, 曲线肘点处对应的距离为最优  $\varepsilon_{opt}$ , 即:

$$\varepsilon_{opt} = \arg \max \left| \frac{d^2 d_k(\mathbf{Y}_i)}{d_i^2} \right| \quad (8)$$

其中,  $d_k(\mathbf{Y}_i)$  为分量  $\mathbf{Y}_i$  到其第  $k$  近邻的距离。最终算法输出聚类分组  $\{\mathbf{C}_1, \mathbf{C}_2, \dots, \mathbf{C}_m\}$  及无关分量集  $\mathbf{N}$ , 实现 ISGMCs 的有效聚类。

$$\mathbf{C} = \mathbf{C}_1 + \mathbf{C}_2 + \cdots + \mathbf{C}_m + \mathbf{N} \quad (9)$$

其中,  $\mathbf{C}_m$  为聚类辛几何模态分量 (clustering symplectic geometric modal component, CSGMC)。

#### 5) 综合评价指标

峭度量化信号冲击强度, 能量谱熵 (spectral entropy, SE) 表征频谱能量聚集性, FKE 联合上述指标, 实现对信号中的非周期性冲击成分的有效筛选。其计算过程包括:

(1) 计算分量峭度, 即:

$$K_i = \frac{E[(C_i - \mu_i)^4]}{\sigma_i^4} \quad (10)$$

式中:  $\mu_i$  为分量均值;  $\sigma_i$  为标准差; 分子  $E[(C_i - \mu_i)^4]$

描述信号分布的尖锐程度。

(2) 计算分量谱熵, 即:

$$SE_i = - \sum_{k=1}^M p(f_k) \log_2 p(f_k) \quad (11)$$

式中:  $M$  为频率点数;  $p(f_k)$  为归一化功率谱。

(3) 计算 FKE 联合指标, 即:

$$FKE_i = \frac{K_i}{SE_i} \quad (12)$$

FKE 值越高, 表明分量同时具有高冲击性与频域能量集中性。根据最大化类间方差计算得到阈值  $\theta$ , 筛选 FKE 值大于  $\theta$  的分量进行重构, 可有效提取断路器声音信号中的非周期性冲击事件, 最终得到重构时间序列  $x(n)$ 。

### 1.2 S 变换

有效的时频分析是事件精确定位的关键。对于经

ISGMD 重构的信号为  $x(n)$ , 其 S 变换可表示为:

$$S(\zeta, f) = \int_{-\infty}^{+\infty} x(t) \frac{|f|}{\sqrt{2\pi}} e^{-\frac{f^2(t-\zeta)^2}{2}} e^{-i2\pi ft} dt \quad (13)$$

其中,  $\zeta$  为时移因子表示窗函数的中心位置,  $f$  为频率。S 变化使用高斯窗函数, 其宽度随频率增加而变窄, 因此兼具多分辨率分析能力和单频独立分析能力, 时频分辨率较高。

### 1.3 融合 TFA 的声音事件检测网络

针对断路器声音事件的时频耦合特性, 提出 TFA-CNN-Bi-LSTM 复合网络, 结构如图 2 所示。该模型将 S 变换后的时频图映射为事件序列标签。针对断路器瞬态事件时频聚集特性, 通过嵌入 TFA 机制增强 CNN 在时频特征提取中的感知能力, 优化事件敏感区域识别。

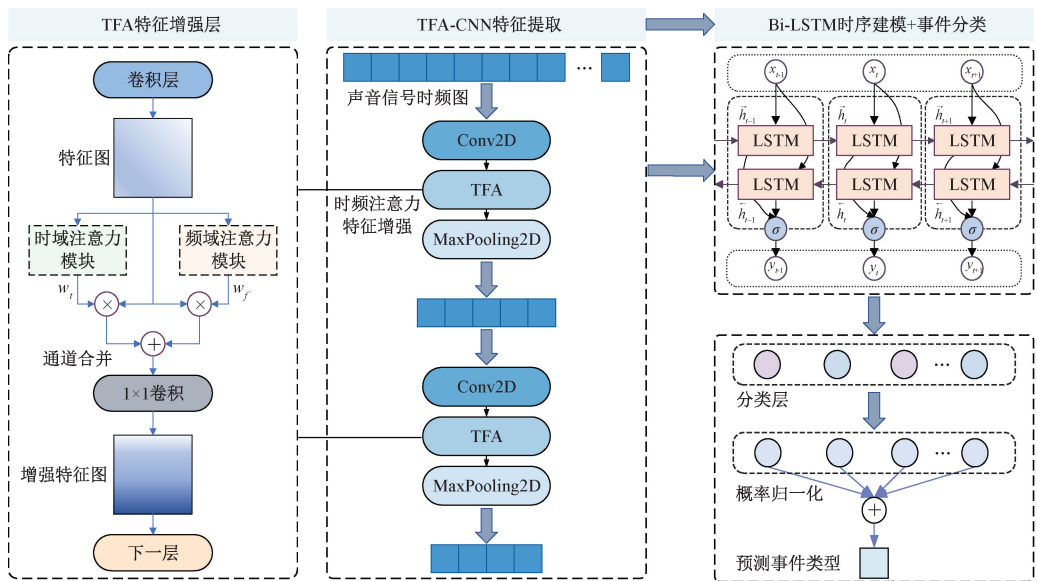


图 2 声音事件检测网络结构

Fig. 2 Sound event detection network architecture

1) TFA 采用双通路异构池化结构, 分别计算时域和频域注意力权重, 权重计算模块结构如图 3 所示。

时域注意力: 通过频率维全局平均池化 (global average pooling, GAP) 与全局最大池化 (global max pooling, GMP) 提取时序显著特征, 经卷积融合与激活生成时域权重  $w_t$ , 聚焦事件持续时段:

$$w_t(t) = \sigma(\text{Conv}_{1D}(GAP_t + GMP_t)) \in [0, 1]^T \quad (14)$$

频域注意力: 通过对时间轴压缩和类似池化操作, 生成频域权重  $w_f$ , 增强关键频带响应。最终通过张量乘法实现特征自适应增强, 达成时域聚焦、频带选择与无关分量抑制三重优化。

2) Bi-LSTM 对 TFA-CNN 输出的特征序列进行双向状态传递, 捕捉长时依赖, 进一步挖掘时序特征, 有效提

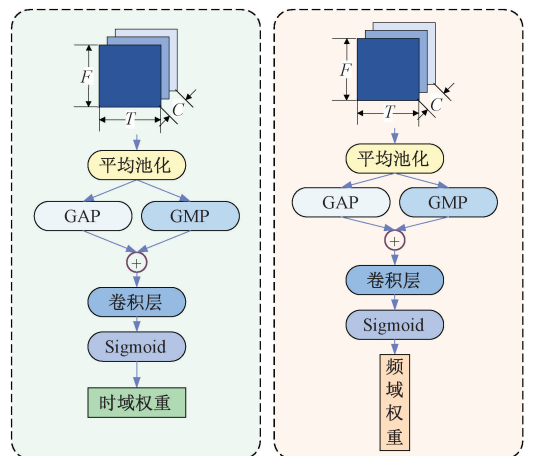


图 3 时频注意力机制结构

Fig. 3 Structure of time-frequency attention mechanism

升瞬态信号的建模精度与分类能力,最终经全连接和 Softmax 输出事件类型。该方法依据类型突变来进行事件定位,计算各时间参数,避免短时分析法在事件边界处的漏判与误触发问题。

## 2 断路器机械特性试验

### 2.1 试验系统设计

本文以壳架等级 1 000、额定电流 200 A 的 A 型号断路器为研究对象,为模拟实际带载工况,并鉴于实验室的功率容量限制,设置试验电压 380 V,并配置纯阻性负载,设置电流为 50 A。在欠压脱扣器持续供电条件下,对其操作机构的储能、合闸、分闸 3 个过程循环运行。试验操作频率设定为 30 次/h,每次均完成完整动作流程。系统由虚拟仪器软件、逻辑控制和数据采集三大模块组成。通过 LabVIEW 控制 PCI-1735U 板卡输出逻辑电平,驱动选项合闸板通断,实现对断路器动作的时序控制。主回路通断由晶闸管及驱动板根据合分闸信号调控。声音信号使用 MP251 压力场传声器配合 MA231 前置放大器采集,布置于线圈及操作机构附近。主轴角位移由 BRT38 绝对值编码器经联轴器连接主轴测量。触头电压通过 CHV-1 000 V 霍尔传感器测量。所有信号由 EM9108S 采集卡同步采集,采样时长为 2 s,以覆盖完整的动作过程。采样率设定为 128 kHz,旨在满足后续时频分析对原始信号的要求。试验对象及传感器布置如图 4 所示。




图 4 试验对象及传感器安装位置

Fig. 4 Test object and sensor installation positions

压力场传声器具有明显的近场响应特性,对距离较近的声源更为敏感,能够有效捕捉目标断路器动作过程的声学特征,同时一定程度上抑制来自其他方向或较远声源的干扰。尽管本试验在单台断路器上进行,但由

于压力场传声器的指向性与近场接收特性,在声波叠加环境下,各断路器所产生的声信号在传播中随距离衰减明显,通过合理布置传声器位置,可有效突出目标设备的声音特征,抑制非观测对象的干扰。

### 2.2 基于事件划分的断路器动作过程分析


#### 1) 合闸过程

断路器声音信号蕴含丰富的机械状态信息,可直接反映内部机构动作序列。通过同步采集主轴角位移、触头电压以及声音信号,建立了合闸过程机械事件与声学特征的映射关系,为聚焦于断路器动作的瞬态过程,分析采用以动作为中心的 60 ms 数据窗口,如图 5(a) 所示。合闸过程可分为 4 个阶段:


(1) 储能释放启动( $0 \sim t_0$ ): 合闸指令触发后,闭合电磁铁驱动铁芯运动,于  $t_0$  时刻撞击连杆机构,声音信号出现首个冲击脉冲,主轴角位移无明显变化,定为事件 1。

(2) 触头系统动作( $t_0 \sim t_1$ ): 储能弹簧释放能量,驱动动触头运动,在  $t_1$  时刻,触头电压降为零,标志动静弧触头接触。此时为触头系统刚合点,声音呈现高频冲击特征,定为事件 2。

(3) 机构运动至死区( $t_1 \sim t_2$ ): 弧触头接触后,动触头继续运动至主触头闭合,主轴在  $t_2$  时刻达到最大位移点。



(a) 合闸过程  
(a) Closing process



(b) 分闸过程  
(b) Opening process

图 5 合/分闸动作过程分析

Fig. 5 Closing and opening operation process analysis

(4) 机构锁定与稳定( $t_2 \sim t_3$ ):剩余动能驱动连杆压缩触头弹簧,至  $t_3$  时刻驱动杆越过死区锁定,声音呈衰减振荡,表征能量耗散,此时定为事件 3。

2) 分闸过程

分闸过程事件对应关系如图 5(b) 所示,分为 3 个阶段:

(1) 脱扣触发阶段( $0 \sim t_4$ ):分闸指令触发铁芯运动,在  $t_4$  时刻撞击解扣机构,释放分闸弹簧。声音出现小幅变化,此时定为事件 4。

(2) 触头分离加速( $t_4 \sim t_5$ ):脱扣后弹簧势能转化为动能。 $t_5$  时刻为主轴角速度峰值,对应触头分离瞬间,声音呈现高频脉冲,此时定为事件 5。

(3) 机构制动( $t_5 \sim t_6$ ):动触头向分闸极限运动。声音振幅指数衰减,在  $t_6$  时刻与止停销撞击,声音出现最大幅值脉冲,定为事件 6。

提取关键时间参数,如表 1 所示。

表 1 关键时间参数及其含义

Table 1 Key time parameters and their interpretation

操作过程	时间参数	计算过程	物理含义
合闸过程	机构动作时间	$T_1 = t_1 - t_0$	操作机构响应速度
	超程时间	$T_2 = t_3 - t_1$	触头系统超程运动与缓冲特性
分闸过程	机构动作时间	$T_3 = t_5 - t_4$	脱扣机构响应效率
分闸过程	开距时间	$T_4 = t_6 - t_5$	机械制动过程阻力与卡涩情况

3 基于断路器声音信号的实例分析

3.1 基于频域特征的断路器动作关键事件分析

为识别事件特征频率并验证 ISGMD 与 S 变换的有效性,对合分闸关键事件时刻声音信号进行频域分析。随机选取 3 次试验结果,通过截取关键点的 3 ms 信号窗进行快速傅里叶分析。

1) 合闸过程

由图 6 合闸过程频谱可知,储能解锁时刻  $t_0$  主峰为 0.8 kHz,宽频分布于 0.5~2 kHz,反映弹簧机构多组件碰撞激励;触头刚合点  $t_1$  在 1.6~1.8 kHz 窄带聚集,中心频率为 1.7 kHz;机构稳态  $t_3$ :能量扩散至 1.5~5 kHz。

通过频带能量比指标定量验证事件频域可分性,计算公式如式(15)所示。

$$R = \frac{\int_{B_i} S(f) df}{\int_{\Sigma} S(f) df} \quad (15)$$

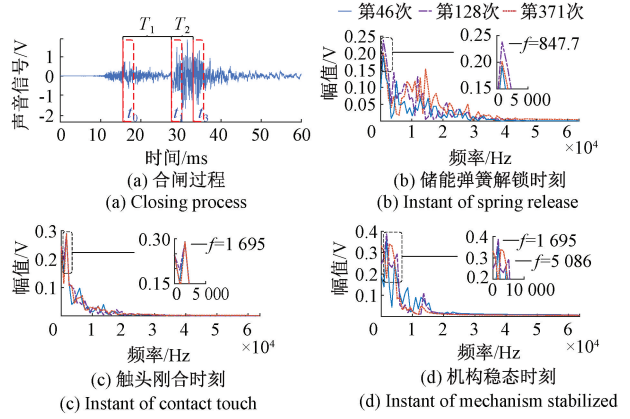


图 6 合闸关键事件时刻频谱

Fig. 6 Spectrum at key events during closing operation

3 类事件计算结果分别为:储能弹簧解锁( $B_1 = 0.3 \sim 1.1$  kHz)、触头刚合( $B_2 = 1.5 \sim 1.9$  kHz)、机构稳态( $B_3 = 1.8 \sim 5$  kHz)的  $R$  值分别为 0.64、0.78、0.59,证实事件在频域的可分离性。

2) 分闸过程

分闸过程呈现高频冲击与模态衰减复合特性。由图 7 分闸过程频谱可知:锁扣解锁频率主峰为 13.6 kHz,能量集中于 10.2~15.3 kHz;触头刚分主峰位于 3.3 kHz,呈 2~15 kHz 宽频分布;开距最大时刻主峰为 2.5 kHz,幅值接近 0.4 V,反映动触头与限位器的剧烈碰撞。

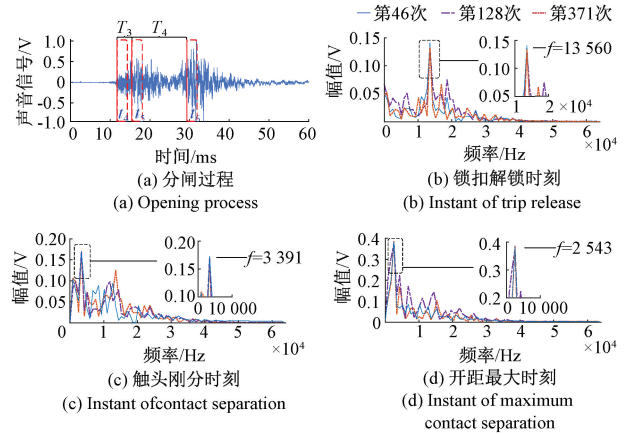


图 7 分闸关键事件时刻频谱

Fig. 7 Spectrum at key events during opening operation

基于对事件信号的频域分析,其主要成分的频率集中于 15 kHz 以内,该结果验证了本试验采用 128 kHz 的采样率遵循了奈奎斯特采样定理,确保信号被完整、无混叠地采集,为后续分析提供了可靠的原始数据。

3.2 基于 ISGMD 的模态分解与选取

使用 ISGMD 分解断路器合分闸过程声音信号,其中以合闸信号为例,使用 SGMD 在相空间下分解为 258 个

ISGMCs。DBSCAN 聚类方法邻域半径确定依据如图 8(a)所示:在  $k$ -距离图中,曲率最大值点即为“肘点”,据此设定邻域半径  $\varepsilon = 105.81$ ;最小样本数  $MinPts$  根据式(7)取值为 6。各初始分量经  $t$ -SNE 降维投影的聚类分布如图 8(b)所示,总共生成了 6 个簇,其余五角星图标代表无关分量,即过分解信号,可见该聚类算法能够根据密度区域有效实现对各分量的划分。每个簇内的分量在其频带范围内具有相似性,将同属一个簇的分量进行融合得到 6 个 CSGMCs,其时域波形及对应频谱如图 9 所示。由频谱可知,各融合分量的中心频率沿分量索引递增,但幅值随频率升高单调递减,此外,各分量中心频率分离度较高,且频域无混叠,说明该方法未损失断路器动作事件中的有效信息,实现了信号的阶梯式频率解耦。

进一步利用融合指标对 DBSCAN 聚类生成的 6 个 CSGMCs 进行量化评估,如图 10(a)所示。根据最大化类间方差确定阈值,将数据分为两组,使得组间差异最大,经计算可得, FKE 阈值  $\theta$  为 1.5,筛选评价指标较高的前 3 个分量进行重构,获得最终模态分解结果。重构信

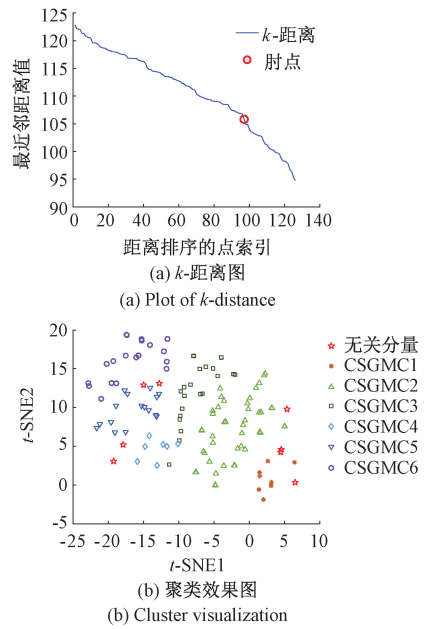


图 8 DBSCAN 聚类参数优化与特征空间分布可视化  
Fig. 8 DBSCAN clustering parameter optimization and feature space distribution visualization

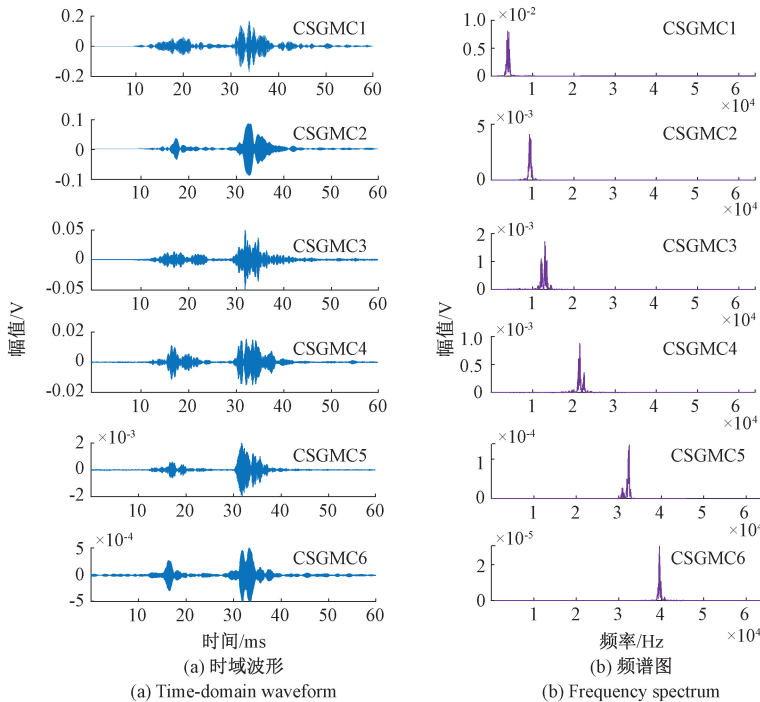


图 9 CSGMCs 及其频谱  
Fig. 9 CSGMCs and its spectrum

号的时域波形及频谱分布如图 10(b)、(c)所示。频谱分析表明,重构信号保留了 3.1 节所述断路器关键事件特征频段,表明 ISGMD 有效实现了声音信号中特征模态分量选取与重构。这些经过筛选和重构的、频域分离的

CSGMCs,各自代表不同的频带,共同覆盖了断路器动作事件所激发的主要频段。它们本质上是经过提纯的信号,通过进一步分析其时频分布特征,可精准识别出嵌入在不同频段中的具体动作时刻。

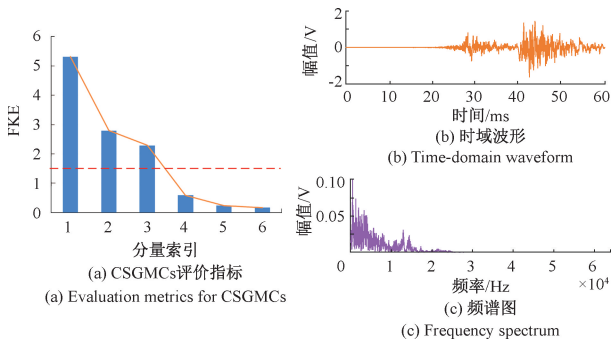


图 10 综合评价指标和 ISGMD 结果

Fig. 10 Comprehensive evaluation metrics and ISGMD results

如图 11 所示,针对  $t_1$  断路器触头碰撞等幅值变化明显的瞬态事件,短时能量与短时能熵比均能有效识别。短时能熵比因融合能量与熵值特征,对非平稳信号更为敏感,在识别弱事件,如  $t_0$  储能弹簧解锁时,略优于短时能量。然而,二者均依赖时域幅值突变,难以提取频域或时序深层特征,对时域重叠、分离度不明显的复合事件,如  $t_3$  机构稳态时刻的判别能力有限。此外,时域分析法对帧长、帧移等参数敏感,且常需配合双门限判决机制,参数调节复杂,耦合性强,削弱了方法的鲁棒性与工程适用性。因此,在事件识别中需引入频域特征与能量分布信息,以缓解因信号特征弱化导致的事件误判与漏判问题。




图 11 两种时域分析方法识别效果

Fig. 11 Recognition performance of the two time-domain analysis methods

### 3.3 基于 S 变换的声音信号时频域分析

本节对 S 变换、STFT、梅尔倒谱图和 Morlet 小波变换 4 种典型时频分析算法进行对比分析,图 12(a) 为时域信号,图 12(b)~(e) 分别为 4 类时频图。

S 变换时频图在时-频二维平面中呈现显著的椭圆形聚焦斑块,其泪滴形状精确定位断路器动作的冲击事件特征,表明在时频分辨率平衡性方面,S 变换窗口自适应机制显著优于固定窗函数算法。相较之下,STFT 虽维持良好频域分辨率,但时域模糊效应导致冲击事件边界扩散;梅尔倒谱图因尺度压缩丢失时间轴定位信息,仅能反映宏观频域分布;Morlet 小波变换虽突出高频成分,但基底噪声抬升使得特征斑块信噪比下降。

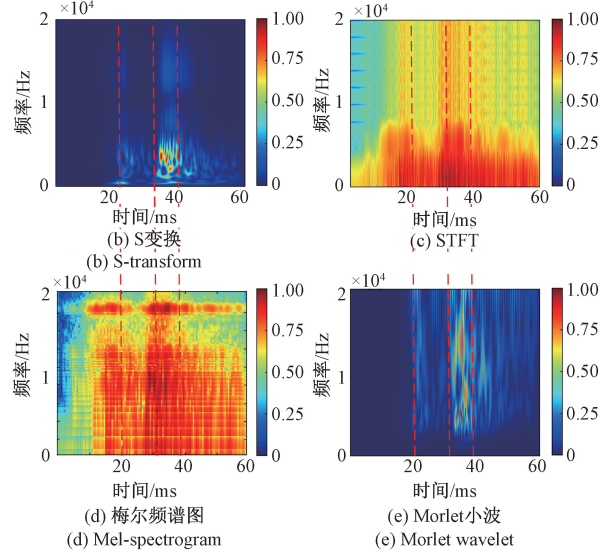



图 12 不同频方法对比

Fig. 12 Comparison of different time-frequency methods

在时频分析中,Renyi 熵被用作衡量时频分布能量聚集程度的判据,通过一个可调节参数  $\alpha$  实现对概率分布特性的敏感度量。熵值越小,代表时频表示具有更高的清晰度,信息提取性能更优。

各时频方法的 Renyi 熵如表 2 所示,S 变换的熵值低于其他 3 种时频方法。这一结果明确体现了 S 变换在能量集中性的显著优势。S 变换凭借其核函数的时频自适应能力,在冲击信号分析中兼具毫秒级时间分辨能力与高频特征保持能力,所得到的时频图像凸显了断路器动作过程中的瞬态事件时频域特征,这一特性为后续事件定位提供直观的视觉判据支撑。

表 2 不同频方法的 Renyi 熵结果

Table 2 Results of Renyi entropy for different time-frequency methods

时频方法	S 变换	STFT	梅尔倒谱图	Morlet 小波
Renyi 熵	12.56	18.14	16.34	15.47

### 3.4 声音事件检测网络训练结果与分析

#### 1) 时频图及标注生成

对试验得到 400 组合分闸数据进行处理后,经 S 变换转为时频图,时频图尺寸设置为时间步×频率点数,保

证时频图时间轴与事件标签序列严格同步。时间步根据 128 kHz 采样频率及 60 ms 时长设置为 7 680 点,频率维度点数设置为 256,在保障频率分辨率的同时兼顾模型计算效率。根据断路器运动特性,标签采用阶梯式区间编码。为避免瞬时事件导致样本失衡问题,将事件持续期纳入同标签区间。以合闸过程为例,事件标签划分、合闸过程参数测量结果如图 13 所示。




图 13 合闸事件标签划分

Fig. 13 Closing event label segmentation

## 2) 模型训练与性能验证

### (1) 模型架构

TFA-CNN-Bi-LSTM 网络以时频图为输入,按时间步输出预测事件类型。网络具体模块及参数设置包括:

a. TFA-CNN:输入时频图经三层卷积-TFA-池化结构处理,每层的卷积核个数分别为 16、32 和 64,卷积核尺寸设置为 3×3;最大池化尺寸设置为 2×1,压缩频率维度 50%,保留时间完整性。

b. 特征重构层:Reshape 操作将三维张量重塑为时间步×特征维度序列,作为后续输入。

c. 双向时序建模层:2 层 Bi-LSTM,尺寸分别为 64 和 32,经过全连接层输出事件类别。

### (2) 评价指标

本文采用精确率、召回率和 F1 分数综合评价分类效果。在多分类任务中,通过对比预测结果与真实标签的匹配关系来评估模型性能。真阳性(true positive, TP):指样本的真实标签为正,模型预测结果也为正;假阴性(false negative, FN):指样本真实标签为正,但模型预测为负;误报(false positive, FP):指标签类型为负例,但模

型预测为正例。

精确率  $P$  表示分类为正例的样本中正确分类的比例;召回率  $R$  为所有实际正例中,正确分类为正例的比例; $F1$  分数为两者的总和平均值,对于一个正例  $i$ ,上述 3 个指标计算过程如式(16)所示。

$$\begin{cases} P_i = \frac{TP_i}{TP_i + FP_i} \\ R_i = \frac{TP_i}{TP_i + FN_i} \\ F1_i = \frac{2P_i \cdot R_i}{P_i + R_i} = \frac{2TP_i}{TP_i + (FN_i + FP_i)/2} \end{cases} \quad (16)$$

在多分类问题中,需要将每个类别的分类效果进行独立计算后取平均,准确率、召回率和 F1 分数被改写为:

$$\begin{cases} P = \frac{\sum_{i=1}^c P_i}{C} \\ R = \frac{\sum_{i=1}^c R_i}{C} \\ F1 = \frac{\sum_{i=1}^c F1_i}{C} \end{cases} \quad (17)$$

### (3) 训练与效果分析

模型采用 TensorFlow 框架搭建,计算机配置为 CPU:i5-9300,GPU:NVIDIA GTX 1650,训练过程采用 Adam 优化器,学习率为 0.001,设置数据集比例为 7:1:2,模型训练回合数为 200,并设置早停机制。稀疏多分类交叉熵损失函数(sparse categorical crossentropy entropy, SCCE)鼓励学习稀疏的类别分布,可以使模型更关注真正重要的类别,更适合 SED 这种类别不平衡的问题。这种损失函数会对样本权重进行自动缩放,无需手动调整权重,计算公式如式(18)所示。

$$Loss = -\frac{1}{m} \sum_{i=1}^m \sum_{j=1}^k y_{ij} \log \hat{y}_{ij} \quad (18)$$

为验证所提 TFA-CNN-Bi-LSTM 模型的分类性能,将所提分类方法与 CNN-LSTM、CNN-Bi-LSTM 进行对比分析,考虑到模型对比的公平性,对其中相同的模型超参数设定统一数值,并通过结果分析本文提出模型的优越性。不同模型评价指标如表 3 所示。

表 3 3 种模型的测试结果

Table 3 Test results of three models (%)

模型	精确率	召回率	F1 分数
CNN-LSTM	86.74	86.25	86.28
CNN-Bi-LSTM	90.38	90.75	90.82
TFA-CNN-Bi-LSTM	93.04	92.96	92.97

数据显示,各深度学习准确率均高于 86%,证实了人工智能方案在断路器动作事件检测中的可行性。所提模型的核心指标均在 93% 左右,较 CNN-LSTM、CNN-Bi-LSTM 平均提升 2.6%~6.7%,验证了 TFA 模块对时频特征提取的增强效果。如图 14 所示,该模型在合分闸过程 8 类事件中取得了较为精准的识别率,有效克服了样本分布不均导致的类型识别偏差问题,实现了高鲁棒性的动作事件识别。





图 14 模型分类混淆矩阵

Fig. 14 Model classification confusion matrix

为提升事件起始判定的鲁棒性并减少瞬时分类误差的干扰,设定当某事件类型持续时长超过 20 个时间步,才将其对应时刻标记为事件起点,并据此生成预测事件序列,如图 15 所示。该方法在断路器合闸与分闸事件定位中,各事件定位误差均小于 40 个时间步,绝对误差在 0.32 ms 之内,表明模型在毫秒级事件检测中具有较高的可靠性。

### 4 算法适用性分析

#### 4.1 传声器布局

本节主要分析传声器布局对声音信号测量结果的影响,重点考察位置与距离因素。依据断路器典型安装环境,选取其前方和上方两类典型位置,如图 16 所示,并在

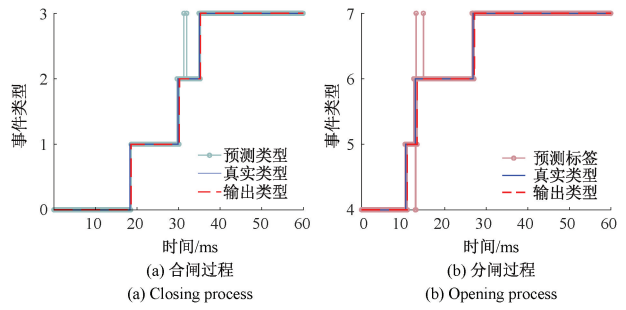


图 15 事件识别结果

Fig. 15 Event identification results

每处设置 3、20 cm 两种距离,于 4 种组合条件下各采集 50 组数据,以研究其对声音信号时频特性以及关键时间参数的差异化作用。





图 16 传声器位置示意图

Fig. 16 Microphone position schematic

图 17 为不同位置及距离下断路器合闸声音信号经 ISGMD-S 变换后的时频对比。断路器内部机构碰撞中存在随机性,时频分布虽有差异,但总体能量分布趋势呈现规律:传声器放置于上方时更接近触头系统,触头碰撞能量更强,且距离越近越显著;置于前方时,声波经机构内部腔体与部件传播,路径复杂,附件机构碰撞能量较为突出。






图 17 不同位置声音信号时频图对比

Fig. 17 Comparison of time-frequency diagrams for sound signals at different positions

为量化评估传声器布设对时间参数测量稳定性的影响,以 2.2 节所述的基于位移、触头电压换位检测方式的传统测量方法测量结果为参照,采用均方根误差 (root mean square error, RMSE) 进行评价,计算公式如式 (19) 所示。

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (19)$$

式中:  $n$  表示样本数量;  $\hat{y}_i$  和  $y_i$  分别表示第  $i$  个样本的预测值与真实值。计算结果如表 4 所示,结果显示,尽管存在机构碰撞随机性及传声器布设差异,模型事件识别结果仍较精准,动作时间参数误差较小,表明所提方法具有良好鲁棒性。

表 4 不同传声器位置测试结果

Table 4 Test results at different microphone positions

传声器位置	时间参数	性能指标 RMSE/ms	传声器位置	时间参数	性能指标 RMSE/ms
上方 3 cm	$T_1$	0.31	前方 3 cm	$T_1$	0.28
	$T_2$	0.35		$T_2$	0.32
	$T_3$	0.39		$T_3$	0.37
	$T_4$	0.27		$T_4$	0.33
上方 20 cm	$T_1$	0.35	前方 20 cm	$T_1$	0.31
	$T_2$	0.38		$T_2$	0.36
	$T_3$	0.44		$T_3$	0.41
	$T_4$	0.42		$T_4$	0.29

### 4.2 断路器规格

为验证所提方法对不同断路器个体及型号的适用性,选取两台同为 A 型号断路器#1、#2 和一台壳架等级 2 000、额定电流 1 250 A 的 B 型断路器#3 开展不同设备间的测试。以主轴角位移和触头电压信号对声音特征事件进行标定,通过对比 3 台设备标定信号及其时频图,如图 18 所示。

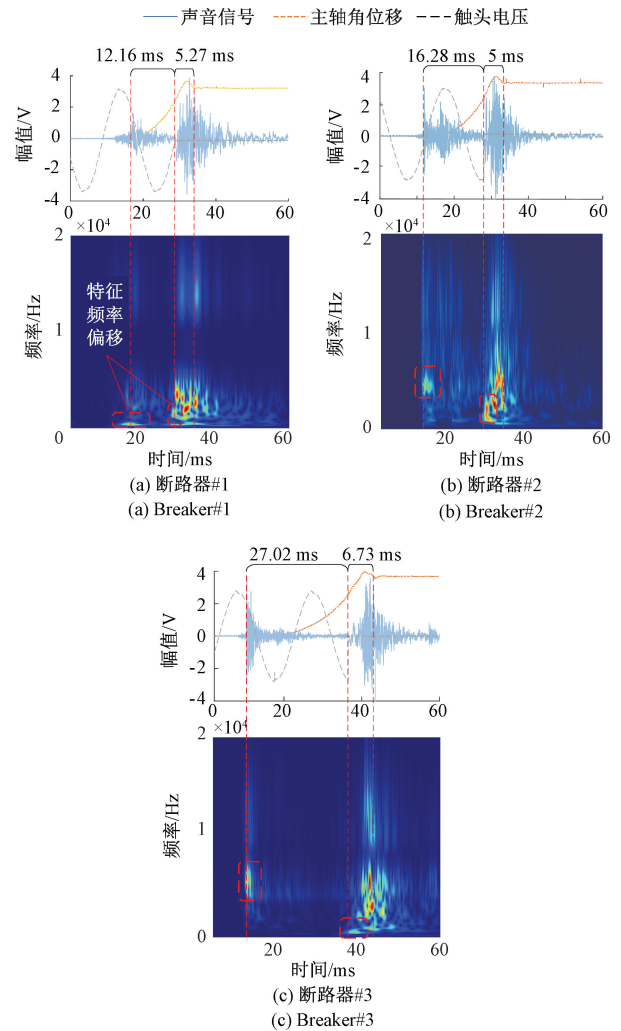


图 18 3 台断路器合闸信号时频图对比

Fig. 18 Comparison of closing signal time-frequency spectrograms for three circuit breakers

能够发现同型号断路器因制造公差导致特征频率偏移,不同型号间因内部机构存在区别也存在时频分布差异。以断路器#1 数据训练模型,对#2 和#3 进行测试,其动作时间参数的 RMSE 结果如表 5 所示。结果表明,所提方法在设备测试中性能良好,主要归因于网络结构优化设计:通过动态计算时域与频域注意力权重,自适应增强事件相关频带响应,有效抑制频率偏移;CNN 通过卷积核在时频图中提取具有泛化能力的局部特征,避免模型过拟合于特定设备,提升对不同断路器的适应性与稳定性;Bi-LSTM 充分挖掘信号前后时序依赖关系,增强对事件序列中短时动态特性的建模能力,进一步提高事件边界识别的准确性。上述内容共同作用,使模型在未参与训练的设备上各项参数 RMSE 均低于 0.57 ms,仍保持良好的测量精度与设备兼容性。

表5 不同断路器测试结果

Table 5 Test results of different circuit breakers

断路器型号	时间参数	性能指标 RMSE/ms
#2	$T_1$	0.46
	$T_2$	0.35
	$T_3$	0.34
	$T_4$	0.32
#3	$T_1$	0.41
	$T_2$	0.35
	$T_3$	0.57
	$T_4$	0.26

## 5 结 论

本研究提出了一种融合模态分解与数据驱动的断路器动作过程时间参数测量方法。

1) 提出了ISGMD方法,在SGMD的基础上通过引入参数自适应DBSCAN聚类和FKE量化准则自动筛选冲击敏感分量,有效克服了传统SGMD中存在的模态过分解及依赖人为设定迭代终止条件的问题,提升了解析的自适应性与可解释性。

2) 设计了TFA-CNN-Bi-LSTM模型,结合TFA机制增强对时频耦合特征的提取能力,并借助Bi-LSTM对时间序列依赖关系进行建模,输出各时间步的事件类型,该网络在事件定位任务中 $F1$ 分数为92.97%,事件定位误差均小于0.32 ms,相较于基准模型评价指标平均提升了2.6%~6.7%。

3) 通过多位置传声器布设及不同断路器设备测试验证了所提方法的鲁棒性。在不同布设条件下,模型参数计算RMSE均 $<0.44$  ms;在不同设备测试中,各项时间参数RMSE $<0.57$  ms,表明方法对传感器位置变动和设备个体差异均具备良好的适应性与稳定性。

在断路器退化过程中,尽管声音事件的特征频率可能发生偏移,但特征提取网络所展现的对不同规格断路器事件的识别能力,表明其对时频图特征分布具有一定适应性,为该方法在机构老化状态下的动作特性诊断提供了潜在可能。然而,该方法在长期机械退化场景中的有效性与鲁棒性仍需进一步系统验证。未来工作将重点围绕3个方面展开:1) 扩充样本库,纳入不同退化状态和机械老化程度下的断路器声音信号数据;2) 是引入迁移学习,以提高小样本场景下模型泛化能力;3) 是深入研究参数退化机制,验证所提取时间参数在断路器机械退化评估中的实际应用价值。

## 参考文献

- [1] 王紫正,宋晓通,刘欣博,等. 基于双目视觉的断路器运动特性检测技术[J]. 高电压技术, 2025, 51(11): 5526-5538.  
WANG Z ZH, SONG X T, LIU X B, et al. Motion characteristics detection technology of breaker based on binocular vision [J]. High Voltage Engineering, 2025, 51(11): 5526-5538.
- [2] 《“十四五”现代能源体系规划》辅导读本[J]. 宏观经济研究, 2022(12): 2.  
Tutorial reading of the "14th Five-Year Plan" for modern energy system [J]. Macroeconomics Research, 2022(12): 2.
- [3] 孙曙光,王浩宇,王景芹,等. 基于空间运动特性的断路器健康状态识别[J]. 仪器仪表学报, 2024, 45(10): 50-62.  
SUN SH G, WANG H Y, WANG J Q, et al. Circuit breaker health state identification based on spatial motion characteristics [J]. Chinese Journal of Scientific Instrument, 2024, 45(10): 50-62.
- [4] 王艳新,闫静,王建华,等. 基于特征融合度量学习的高压断路器机械故障诊断[J]. 仪器仪表学报, 2022, 43(9): 98-105.  
WANG Y X, YAN J, WANG J H, et al. Mechanical fault diagnosis for high voltage circuit breaker via novel feature fusion metric learning [J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 98-105.
- [5] 刘会兰,李想,赵书涛,等. 断路器控制线圈驱动铁芯动作特性及其电流-动作关联特征的机械故障辨识方法[J]. 高电压技术, 2025, 51(4): 1901-1911.  
LIU H L, LI X, ZHAO SH T, et al. Mechanical fault identification method based on action characteristics of circuit breaker control coil driving the iron core and its current-action correlation features [J]. High Voltage Engineering, 2025, 51(4): 1901-1911.
- [6] 孙曙光,杨飞龙,陈静,等. 基于振动-电流广域特征与软共享机制的断路器多故障诊断[J]. 仪器仪表学报, 2024, 45(1): 46-59.  
SUN SH G, YANG F L, CHEN J, et al. Multi-fault diagnosis of circuit breaker based on vibration-current wide-domain features and soft sharing mechanism [J]. Chinese Journal of Scientific Instrument, 2024, 45(1): 46-59.
- [7] 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 [2025-08-20].

- ZHAO CH CH, ZHANG G G, LIU J, et al. Mechanical parameter identification and fault diagnosis of high-voltage circuit breaker spring operating mechanisms based on physics-informed and transfer network[J/OL]. Transactions of China Electrotechnical Society, 1-13 [2025-08-20].
- [ 8 ] 胡博凯,李奎,牛峰,等. 低压断路器机械特性状态监测方法研究[J]. 电工技术学报,2022,37(13):3317-3330.
- HU B K, LI K, NIU F, et al. Research on condition monitoring method of mechanical characteristics of low-voltage circuit breaker [ J ]. Transactions of China Electrotechnical Society, 2022, 37(13): 3317-3330.
- [ 9 ] 唐政,严英杰,姚聪伟,等. 基于多源信号特征时序联合分析的高压断路器弹簧操动机构故障诊断方法[J/OL]. 高电压技术,1-12[2025-08-20].
- TANG ZH, YAN Y J, YAO C W, et al. Fault diagnosis method for spring operating mechanisms of high-voltage circuit breaker based on joint analysis of multi-source signal features time-series [ J/OL ]. High Voltage Engineering, 1-12[2025-08-20].
- [10] 刘亚魁,李红运,林天然,等. 基于机器视觉的高压断路器机械特性测量方法[J]. 电工技术学报,2023,38(S1):222-230.
- LIU Y K, LI H Y, LIN T R, et al. Measurement method for mechanical characteristics of high-voltage circuit breakers based on machine vision [ J ]. Transactions of China Electrotechnical Society, 2023, 38 ( S1 ): 222-230.
- [11] 李奎,张月,姜惠,等. 基于触头形貌特征的低压直流断路器可靠性评估[J]. 仪器仪表学报,2024,45(12):118-128.
- LI K, ZHANG Y, JIANG H, et al. Reliability assessment of low-voltage DC circuit breaker based on morphological characteristic of contacts[J]. Chinese Journal of Scientific Instrument, 2024, 45 ( 12 ): 118-128.
- [12] 纪T Y, 刘Z G, 庄X L, et al. Advancing GIS operational monitoring: A novel voiceprint recognition method using grassmann manifold and multi-kernel functions [ J ]. IEEE Transactions on Power Delivery, 2024, 39(5): 2894-2907.
- [13] 孙玉伟,罗林根,陈敬德,等. 基于声音特征与改进稀疏表示分类的断路器机械故障诊断方法[J]. 电网技术,2022,46(3):1214-1222.
- SUN Y W, LUO L G, CHEN J D, et al. Mechanical fault diagnosis of circuit breaker based on sound characteristics and improved sparse representation classification [ J ]. Power System Technology, 2022, 46(3): 1214-1222.
- [14] 夏小飞,易林,饶夏锦,等. 基于声学指纹分析的高压断路器机械故障诊断方法[J]. 高压电器,2021,57(10):66-76.
- XIA X F, YI L, RAO X J, et al. Mechanical fault diagnosis method of high-voltage circuit breaker based on acoustic fingerprint analysis[J]. High Voltage Apparatus, 2021, 57(10): 66-76.
- [15] 李辰辉,褚继峰,龙潇,等. 基于弧触头接触振动特征分析的高压SF6断路器电寿命在线监测方法[J]. 电工技术学报,2024,39(15):4883-4895.
- LI CH H, CHU J F, LONG X, et al. Online monitoring method for electrical life of high-voltage SF6 circuit breakers based on vibration characteristics of arc contact[J]. Transactions of China Electrotechnical Society, 2024, 39(15): 4883-4895.
- [16] 孙曙光,卢梦鑫,王景芹,等. 基于改进时间同步压缩S变换的断路器触头不同时期时间测量[J]. 高电压技术,2025,51(10):5139-5154.
- SUN SH G, LU M X, WANG J Q, et al. Asynchronous time measurement of circuit breaker contacts based on modified time-reassigned S-transform [ J ]. High Voltage Engineering, 2025, 51(10): 5139-5154.
- [17] 万书亭,豆龙江,李聪,等. 基于振动信号的高压断路器合闸特性参数在线检测方法研究[J]. 振动工程学报,2019,32(2):359-367.
- WAN SH T, DOU L J, LI C, et al. Online detection method for closing characteristic parameters of high-voltage circuit breakers based on vibration signals [ J ]. Journal of Vibration Engineering, 2019, 32 ( 2 ): 359-367.
- [18] 王鸣,封皓,沙洲,等. 基于EMD的MZI事件识别方案优化研究[J/OL]. 光学学报,1-17[2025-08-15].
- WANG M, FENG H, SHA ZH, et al. Optimization research on MZI event identification scheme based on EMD[J/OL]. Acta Optica Sinica, 1-17[2025-08-15].
- [19] 孙玉伟,罗林根,陈敬德,等. 含噪背景下基于盲源分离与NSVDD的断路器机械故障诊断方法[J]. 高电压技术,2022,48(3):1104-1113.
- SUN Y W, LUO L G, CHEN J D, et al. Mechanical fault diagnosis method of circuit breaker based on blind source separation and NSVDD under noisy background[J]. High Voltage Engineering, 2022, 48 ( 3 ): 1104-1113.

- [20] PAN H Y, YANG Y, LI X, et al. Symplectic geometry mode decomposition and its application to rotating machinery compound fault diagnosis [J]. *Mechanical Systems and Signal Processing*, 2019, 114: 189-211.
- [21] 陈志刚, 杜小磊, 王衍学. 增强辛几何模态分解和自组织自编码卷积网络的电机轴承工况识别[J]. *振动工程学报*, 2022, 35(4): 958-968.  
CHEN ZH G, DU X L, WANG Y X. Enhanced symplectic geometry mode decomposition and self-organizing autoencoder convolutional network for motor bearing condition recognition [J]. *Journal of Vibration Engineering*, 2022, 35(4): 958-968.
- [22] 郭成, 杨宣铭, 杨灵睿, 等. 基于改进 SOBI-SGMD 算法的次同步振荡模态辨识研究[J]. *电力系统保护与控制*, 2025, 53(14): 100-110.  
GUO CH, YANG X M, YANG L R, et al. Research on subsynchronous oscillation mode identification based on improved SOBI-SGMD algorithm [J]. *Power System Protection and Control*, 2025, 53(14): 100-110.
- [23] 杨利平, 侯振威, 辜小花, 等. 弱标签声音事件检测的空间-通道特征表征与自注意池化[J]. *电子学报*, 2023, 51(2): 297-306.  
YANG L P, HOU ZH W, GU X H, et al. Spatial-channel feature representation and self-attention pooling for weakly-labeled sound event detection [J]. *Acta Electronica Sinica*, 2023, 51(2): 297-306.
- [24] ÇAKIR E, PARASCANDOLO G, HEITTOLA T, et al. Convolutional recurrent neural networks for polyphonic sound event detection [J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2017, 25(6): 1291-1303.

## 作者简介



孙曙光, 分别在 2002 年、2005 年和 2009 年于河北工业大学获得学士学位、硕士学位和博士学位, 现为河北工业大学副教授, 主要研究方向为智能检测与故障诊断。  
E-mail: sunshuguang\_2000@163.com

**Sun Shuguang** received his B. Sc., M. Sc. and Ph. D. degrees all from Hebei University of Technology in


2002, 2005 and 2009, respectively. He is currently an associate professor at Hebei University of Technology. His main research interests include intelligent detection and fault diagnosis.



胡雨辰, 2018 年于河北工业大学获得学士学位, 2023 年于英国伯明翰大学获得硕士学位, 现为中国铁路设计集团助理工程师, 主要研究方向为轨道交通电力变配电所、光伏、电力系统方向等。

E-mail: tels7217@163.com

**Hu Yuchen** received her B. Sc. degree from Hebei University of Technology in 2018, and her M. Sc. degree from the University of Birmingham, in the UK, in 2023. She is currently an assistant engineer at China Railway Design Corporation. Her main research interests include rail transit power transformation and distribution substations, photovoltaic power generation, and power systems.



王景芹 (通信作者), 分别在 1984 年、1986 年和 1997 年于河北工业大学获得学士学位、硕士学位和博士学位, 现为河北工业大学教授, 主要研究方向为电接触和可靠性。

E-mail: jqwang@hebut.edu.cn

**Wang Jingqin** (Corresponding author) received her B. Sc., M. Sc. and Ph. D. degrees all from Hebei University of Technology in 1984, 1986 and 1997, respectively. She is currently a professor at Hebei University of Technology. Her main research interests include electrical contact and reliability.



崔玉龙, 分别在 1990 年、1993 年和 2003 年于河北工业大学获得学士学位、硕士学位和博士学位, 现为北京化工大学副教授, 主要研究方向为电力电子技术应用。

E-mail: 2003500070@buct.edu.cn

**Cui Yulong** received his B. Sc., M. Sc., and Ph. D. degrees all from Hebei University of Technology in 1990, 1993, and 2003, respectively. He is currently an associate professor at Beijing University of Chemical Technology. His main research interests include applications of power electronics technology.