光电技术及应用

DOI: 10.16818/j.issn1001－5868.20250814004

基于多源数据融合的电网调控行为异常监测与诊断

吴岳洲[1*]，蓝　天[1]，陈志伟[1]，缪新新[2]，王振宇[2]

（1. 广东电网有限责任公司电力调度控制中心，广州 510220；2. 南京南瑞信息通信科技有限公司，南京 211100）

摘　要： 在主电网断路器操动机构异常监测中，多维混合特征提取困难，导致分类识别准确率较低。特别是当电网处于恶劣场景中，信号干扰和数据不完整的问题更加突出，进一步增加监测和故障诊断的难度。对此，文章提出一种基于变分模态分解算法与综合式梅尔倒谱系数的多源信号特征提取方法。在该方法的基础上，利用核主成分聚类分析与优化后的支持向量机，最终提出一种新型的主电网断路器操动机构异常监测与诊断技术。实验结果表明，在正常工况下，该研究方法信号的特征提取标准差与均方根值分别为0.10与1.12，验证了其在多源信号特征提取与噪声抑制中的有效性。此外，该方法的最高分类识别准确率达到了97.7%，显示出其在提高异常监测精度和诊断效率方面具有显著优势。所提出的方法不仅能为主电网断路器操动机构的异常监测与诊断提供新的技术路径，还能为实际应用中的多源信号分析提供有效的解决方案，解决军事电网中信号干扰和数据不完整的问题，提升监测与诊断的智能化水平。

关键词： 多源数据；变分模态分解；主电网；断路器；异常监测；诊断

中图分类号： TN911.7；TP274　**文章编号：** 1001－5868(2026)01－0140－09

Multi-Source Data-Fusion-Mediated Abnormality Monitoring and Diagnosis of Power Grid Regulation Behavior

WU Yuezhou[1], LAN Tian[1], CHEN Zhiwei[1], MIAO Xinxin[2], WANG Zhenyu[2]

(1. Power Dispatching and Controlling Center of Guangdong Power Grid Co., Ltd., Guangzhou 510220 CHN; 2. Nanjing NARI Information and Communication Technology Co., Ltd., Nanjing 211100, CHN)

Abstract: Monitoring the abnormalities in the operating mechanism of the main-grid circuit breaker through multi-dimensional hybrid feature extraction is challenging owing to its poor classification performance and low identification accuracy. Therefore, in this study, a multi-source signal-feature extraction technique, based on a variational modal decomposition algorithm with integrated Mayer inverse spectral coefficients, is proposed. This technique is integrated with kernel principal component cluster analysis and optimized support vector machine to develop a new type of method for monitoring and diagnosing the main power-grid circuit breaker operating mechanism. The experimental results show that under normal operating conditions, the standard deviation and root-mean-square value of the proposed signal-feature extraction method are 0.10 and 1.12, respectively, which verify the effectiveness of the proposed method in multi-source signal-feature extraction and noise suppression. In addition, the proposed method achieves the highest classification recognition accuracy of 97.7%. The results demonstrate that the proposed method can improve the accuracy of anomaly monitoring and diagnostic efficiency. It provides a novel technical path for anomaly

收稿日期：2025－08－14.

基金项目：2024年数字电网工单项目(036000HK23120003).

* **通信作者：**吴岳洲

monitoring and diagnosis of the operating mechanism of the main grid circuit breaker. In addition, the proposed method offers an effective solution for the analysis of multi-source signals in practical applications.

Key words: multi-source data; variational modal decomposition; main grid; circuit breakers; anomaly monitoring; diagnosis

0 引言

在现代社会中，电力是一种不可或缺的资源，支撑着各种生活和工业活动的正常运行。为了确保电力供应的稳定性和可靠性，电网监控变得至关重要。电网监控系统不仅可以监测电力系统的运行状况，还具备故障诊断和预测功能，以提前防范潜在的问题[1]。然而，随着电力需求的增加和电网规模的扩大，传统的电网调度方式已难以满足现代主电网的复杂性和实时性要求。尤其在特殊环境中，由于信号干扰和数据不完整的问题，传统监控技术面临更大挑战。多源数据融合技术（Multi-source Information Fusion, MSIF）的出现为电网调控提供了新的视角和解决方案，通过融合不同来源的数据，该技术能够为电网调控提供更精准和全面的信息[2]。已有诸多研究者对其进行探讨。例如，Ke等提出一种基于MSIF的电网变电站安全施工作业感知与预警技术，通过整合现场传感器、图像、视频等多源数据，实现了对安全距离、现场违章、误操作、有害气体等的智能识别与实时预警，显著提高了电网变电站的安全管理和智能化水平[3]。Tao等基于MSIF提出一种基于深度残差收缩网络的供电系统关联故障诊断方法，实验结果表明该方法能够在样本不足和参数缺失的情况下实现高精度的电网故障诊断[4]。Yang等通过MSIF将主电网调控中液压伺服电机的多个压力信号特征进行拼接，提出一种新的故障检测算法，其实验结果表明该算法在特征提取方面具有优越的性能表现，能够准确诊断出液压伺服电机的已知故障[5]。

尽管MSIF在提升电网调控行为的监测和诊断方面具有显著优势，但其仍面临数据预处理和特征提取技术上的挑战。在实际应用中，如何有效处理来自不同来源的数据是提高电网调控智能化水平的关键[6]。变分模态分解算法（Variational Mode Decomposition, VMD）能够在不依赖预设基函数的情况下，将信号自动分解为不同频率的模态，从而为多源数据的融合提供新的思路[7]。Lv等通过多源数据进行季节因素消除和误差修正，提出一种基于VMD和长短期记忆网络（Long Short-Term Memory, LSTM）的新型混合模型，实验结果表明该模型在实际电网负荷数据集上的预测精度显著优于对比模型，有效提升了电网运行的安全性和经济性[8]。Wang等为精确预测非平稳和非线性电力需求多源数据，提出一种结合VMD和遗传算法-反向传播的增强型混合神经网络模型，所提出模型的均方根误差与传统模型的预测性能相比降低了60.36%，平均绝对百分比误差降低了44.34%[9]。Sun等针对电网负荷预测的复杂性，通过多源数据的处理和重构，提出一种基于VMD和LSTM的短期电网电力负荷预测模型，该模型相比传统方法在预测精度和拟合能力上具有显著优势，是一种有效的短期电网电力负荷预测方法[10]。

综上所述，MSIF和VMD能够为电网负荷预测、故障诊断等环节提供精准的技术支持，推动电网在复杂环境下的高效、安全运行。然而，VMD算法在实际应用中仍面临选择模态分解层数的问题。此外，现有的电网故障诊断方法大多依赖单一信号，缺乏针对性和多样化的数据源。尤其是主电网断路器的异常也往往难以直接检测，传统单一方法容易忽视其潜在的故障模式。为解决这些问题，本研究创新性地将VMD与频域判断指标（Frequency Domain Judgment Index, FDJI）、综合式梅尔倒谱系数（C-MFCC）结合，提出一种新型的主电网断路器混合信号特征提取方法。在该方法的基础上，进一步提取了信号的综合特征参数，然后利用核主成分聚类分析（Kernel Principal Component Analysis, KPCA）对这些特征进行降维处理。这些改进构成了研究最终提出的新型主电网断路器异常监测与诊断方法。通过该新型方法，研究旨在提升主电网断路器操动机构异常诊断的准确性与实时性，解决现有方法在多源数据融合和复杂信号处理中的不足，从而有效提升主电网的安全性、稳定性与智能化水平。

1 主电网断路器操动机构异常监测与诊断技术设计

1.1 基于VMD-FDJI-C-MFCC的多源信号特征提取方法

断路器作为主电网调控中的关键设备之一，其状态变化将会直接影响到电网的健康运行。断路器常用的特征信号主要包括振动信号、声音信号以及电流信号[11]。其中，振动信号能够有效反映断路器的机械操作状态和潜在故障。然而，由于操动机构表面振动信号的随机性和非平稳性，这些信号往往呈现出复杂的混叠特征，使得直接分析变得困难[12]。因此，为提高主电网断路器操动机构异常监测和诊断的准确性，必须对信号进行分解处理。近年来，VMD算法作为一种新兴的信号分析方法被提出。该算法通过变分优化的方式将复杂信号分解为一组具有物理意义的本征模态函数，从而有效解决操动机构表面振动信号混叠和非平稳性问题[13]。VMD算法的流程结构如图1所示。

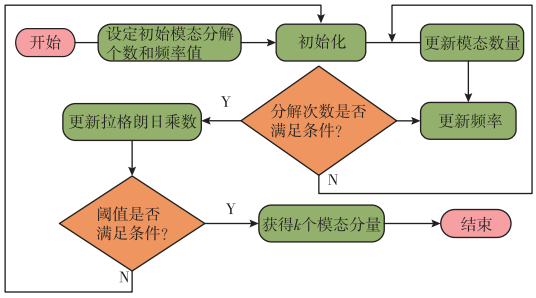


图1 VMD算法流程图

由图1可知，VMD算法的实质就是构造和求解变分问题。该算法的过程首先包括设定初始模态分解个数和频率值，并进行初始化，以启动迭代。在每次迭代中，更新模态数量和频率，逐步调整每个模态的参数。接着，判断是否已达到设定的最大分解次数，若达到则停止迭代，若未达到则继续更新模态频率。随后，检查误差是否满足设定的阈值，误差小于阈值则结束迭代并返回结果，若未达到要求则继续进行下一次迭代，直到满足收敛条件。最终，通过这一循环的迭代过程，获得所需的模态分量。VMD变分模型计算公式为：

$$\min_{\{\boldsymbol{u}_k\},\{w_k\}}\left\{\sum_k\left\|\partial_t\left[\left(\delta(t)+\frac{j}{\pi t}\right)\times\boldsymbol{u}_k(t)\right]e^{-jw_kt}\right\|_2^2\right\} \tag{1}$$

式中，$\boldsymbol{u}_k(t)$代表固有模态分量，w_k代表各IMFs的中心频率集合，$\delta(t)$代表冲激函数，$\left(\delta(t)+\frac{j}{\pi t}\right)$代表希尔伯特变换结果，$\partial_t$代表偏导运算，$k$代表分解的模态个数。各模态分量的计算公式为：

$$\bar{\boldsymbol{u}}_k^{n+1}(w)=\frac{\bar{f}(w)-\sum_{j\neq k}\bar{\boldsymbol{u}}_i(w)+\frac{\lambda(w)}{2}}{1+2\alpha(w-w_k)^2} \tag{2}$$

式中，$\bar{\boldsymbol{u}}_k^{n+1}(w)$代表第$n+1$次迭代更新后的第$k$个模态分量，$\alpha$与$\lambda$分别代表二次惩罚因子与拉格朗日算子，$\bar{\boldsymbol{u}}_i(w)$代表信号的频域表示，$w$代表频率变量，$\bar{f}(w)$代表原始信号的频域表示。通过公式(1)与公式(2)可知，模态分解个数会对VMD的分解效果产生显著影响。为优化VMD算法中模态分解个数的选择，研究选择通过构建FDJI函数的方法来确定最合适的分解个数。FDJI函数构建流程如图2所示。

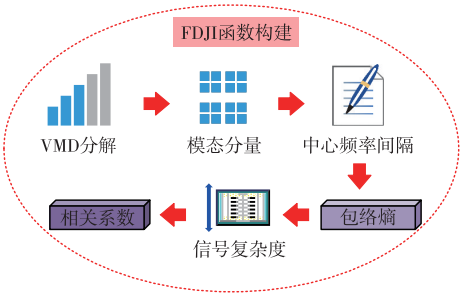


图2 FDJI函数构建流程

由图2可知，研究通过综合考虑中心频率间隔、包络熵和相关系数来构建FDJI函数。首先，进行VMD分解并设定初步的模态分解个数，获得多个模态分量。然后，计算每个模态的中心频率，并根据这些频率评估模态之间的间隔。接着，利用包络熵评估模态的信号复杂度。最后，计算模态之间的相关系数。中心频率间隔计算公式为：

$$\gamma=\frac{\min(\omega_2-\omega_1,\omega_3-\omega_2,\cdots,\omega_k-\omega_{k-1})}{\omega_k-\omega_1} \tag{3}$$

式中，γ代表相邻模态之间的中心频率间隔归一化后的最小值，$\omega_1\sim\omega_k$则代表不同模态分量的中心频率。包络熵E_p的计算公式为：

$$\begin{cases}p_i=\dfrac{h(i)}{\sum_{i=1}^{N}h(i)}\\ E_p=-\sum_{i=1}^{N}p_i\lg(p_i)\end{cases} \tag{4}$$

式中，p_i与N分别代表归一化值与包络信号图的点

数，$h(i)$则代表模态函数 Hilbert 变换后的包络信号。相关系数η计算公式为：

$$\eta=\frac{\mathrm{cov}\left[x_i(t),u_i(t)\right]}{\sqrt{\sigma(x_i)}\cdot\sqrt{\sigma(u_i)}} \tag{5}$$

式中，x_i与σ分别代表原始信号与方差，u_i代表第i个包络信号图点数的模态分量，cov 则代表协方差运算。判断γ，E_p与η的指标函数计算表达式为：

$$\theta_k=\begin{cases}\infty,\gamma<\dfrac{1}{k+1}\\ E_p+\dfrac{2}{\eta_k},\dfrac{1}{k+1}<\gamma<\dfrac{1}{k-1}\end{cases} \tag{6}$$

通过公式(6)便可得到最佳的模态分解层数。声音信号与振动信号相似，也同样包含大量的突变信息，并且具有强烈随机性的不平稳信号。然而，声音信号在频带上的能量分布与振动信号存在差异[14]。因此，针对这些特点，研究引入了 C-MFCC 作为特征参数进行信号特征提取。C-MFCC 是一种结合了 MFCC 和其他特征提取技术优点的声音信号处理方法。该方法通过在滤波阶段根据不同频段选择适当的滤波器组，从而显著提升声音信号特征提取的效果。C-MFCC 特征量提取的流程如图 3 所示。

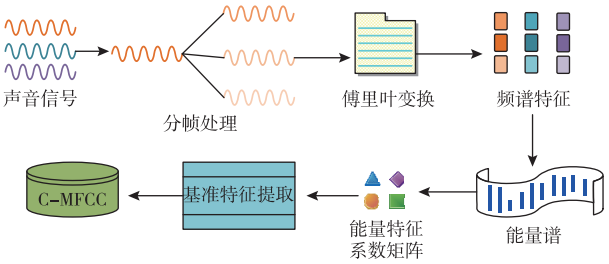


图 3　C-MFCC 特征量提取的流程

由图 3 可知，研究首先对声音信号进行了分帧处理。在此基础上，通过傅里叶变换计算出了每帧信号的频率特征。接着，基于能量谱计算每帧的能量特性，并结合能量谱数据，提取出 36 维的能量特征系数矩阵。进一步通过提取 C-MFCC 基准特征，最终获得了 C-MFCC 的特征向量矩阵。与此同时，电流信号则具有瞬时变化性、周期性变化、非平稳性和噪声干扰等特点[15]。针对这些特点，研究通过对信号的时间和幅值局部特征进行分段处理，计算每段的均值、均方根值和标准差等时域特征，从而有效提取电流信号的特征。综合上述各种改进，研究最终提出一种基于 VMD-FDJI-C-MFCC 的多源信号特征提取方法。

1.2　基于 KPCA-SVM-AWOA-XGBoost 的断路器异常监测与诊断方法

通过所提出的 VMD-FDJI-C-MFCC 多源信号特征提取方法，研究可以从断路器操动机构中有效获得多源信号特征。然而，如果直接采用机器学习算法对其进行分类，计算量将过大。因此，首先引入 KPCA 方法，通过融合各特征参量来提高特征质量，进而提升主电网断路器异常监测与诊断的准确率。KPCA 核函数$K(x,y)$计算表达式为：

$$K(x,y)=\boldsymbol{\phi}(x)\cdot\boldsymbol{\phi}(y) \tag{7}$$

式中，x与y代表两个不同的数据点，ϕ代表映射函数。核函数的目的是评估在高维空间中，由映射函数$\boldsymbol{\phi}(x)$和$\boldsymbol{\phi}(y)$映射后数据点之间的相似性或相关性。在应用核函数之前，通常需要对数据进行中心化处理，以确保映射后的数据均值为零[16]。中心化计算表达式为：

$$\boldsymbol{K}_{\mathrm{centered}}=K-\frac{1}{n}\boldsymbol{K}_{1n}-\frac{1}{n}\boldsymbol{K}_{n1}+\frac{1}{n^2}K_{1n1n} \tag{8}$$

式中，K代表核函数，$\boldsymbol{K}_{1n}$与$\boldsymbol{K}_{n1}$分别代表核矩阵中所有行和列的均值，n代表数据点的数量。

在高维空间中，对中心化的核矩阵进行特征值分解，便可以找到主成分。特征值分解计算表达式为：

$$\boldsymbol{K}_{\mathrm{centered}}(\boldsymbol{a})=\lambda\boldsymbol{a} \tag{9}$$

式中，λ与$\boldsymbol{a}$分别代表特征值与特征向量。经过 KPCA 降维处理后，可以得到新的融合特征矩阵。

随后，通过机器学习算法对样本进行分类，就可实现主电网断路器的异常监测与诊断。研究主要通过自适应优化鲸鱼算法(Adaptive Whale Optimization Algorithm，AWOA)来优化非线性支持向量机(Support Vector Machine，SVM)分类算法。然后，结合梯度提升算法(Extreme Gradient Boosting，XGBoost)对优化后的 SVM 分类器进行加权融合来实现对各样本的有效分类识别。非线性 SVM 算法的结构如图 4 所示。

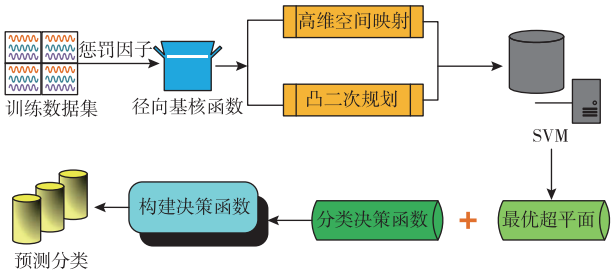


图 4　非线性 SVM 算法的结构

由图4可知，非线性SVM算法主要通过选择合适的径向基核函数，将原始数据映射到高维特征空间，在该空间内实现非线性可分问题的线性化。首先，输入训练数据集并选择合适的惩罚因子。接着，通过径向基核函数将数据映射到高维空间，并构建一个凸二次规划问题来求解最优分类边界。然后，利用SVM来计算最优超平面和分类决策函数的参数。最后，通过构建决策函数，对新的测试样本进行分类预测。径向基核函数的内部参数和非线性SVM的惩罚因子参数需预先确定[17]。研究通过AWOA算法选取这两个参数，从而提升非线性SVM的分类性能。AWOA的流程结构如图5所示。

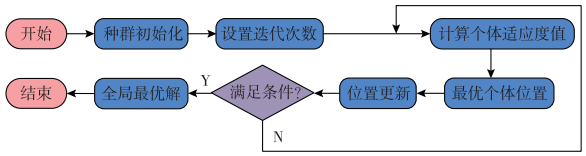


图5 AWOA的流程结构

由图5可知，AWOA算法首先初始化参数并设置迭代次数。然后，计算每个个体的适应度值，并记录当前最优个体位置。接着，根据AWOA算法的三种捕食行为更新个体的位置。通过不断迭代，直到满足停止条件，输出全局最优解。最终，当适应度值达到设定阈值时，算法结束并给出最优解。但断路器操动机构工况复杂，仅依赖SVM分类器无法满足需求。因此，研究引入了XGBoost算法强化SVM分类器，该算法能够通过集成多棵弱学习树来构建一个强大的预测模型[18]。最终，提出了一种基于KPCA-SVM-AWOA-XGBoost的断路器异常监测与诊断方法。该方法整体结构框架如图6所示。

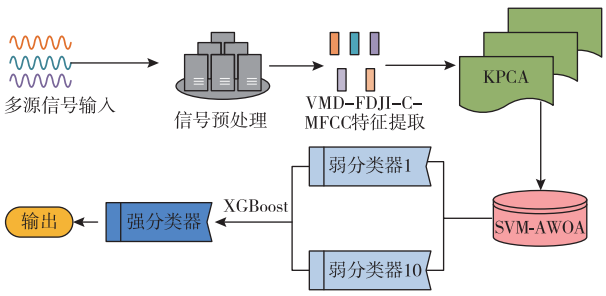


图6 KPCA-SVM-AWOA-XGBoost算法整体结构框架

由图6可知，研究首先采集并分析主电网断路器多源信号数据，以获取用于输入的样本数据。在数据准备阶段，通过VMD-FDJI-C-MFCC算法进行特征提取，并采用KPCA进行数据处理，得到新的融合特征参量矩阵，确保输入数据能够准确反映关键信息。随后，将处理后的数据输入至SVM-AWOA模型中。在此过程中，利用AWOA对SVM分类器的参数进行优化，从而显著提升分类器的性能。优化后的SVM模型通过XGBoost算法进行加权融合，将多个弱分类器的结果整合为一个强分类器，以进一步提高分类准确度。最终，经过这一系列优化后的分类器输出结果，给出最终的分类识别结果。该结果就是电网断电器调控行为异常监测与诊断的结果。各个弱分类器R_j的分类误差E_{err}计算公式为：

$$E_{\mathrm{err}}=\sum_{i=1}^{n}\varpi(i),R_j(x_i)\neq y_i \tag{10}$$

式中，$\varpi(i)$代表分类器的权重，x_i代表样本特征向量，y_i代表对应标签。强分类器$Q(x)$计算表达式为：

$$Q(x)=\mathrm{sign}\left[\sum_{j=1}^{T}\varpi_j L_j(x)\right] \tag{11}$$

式中，ϖ_j与L_j分别代表权重与弱分类器。

2 主电网断路器操动机构异常监测与诊断技术性能测试

2.1 主电网断路器信号特征提取方法性能测试

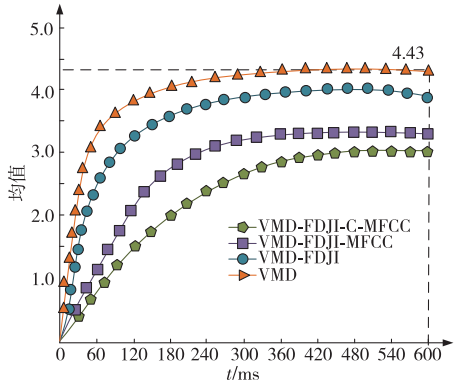
为验证所提出方法的有效性，研究搭建了合适的实验环境，实时采集了LW35-110 kV高压SF6断路器的CT30型操动机构的振动信号、声音信号以及电流信号。CT30型操动机构技术参数如表1所示。

表1 CT30型操动机构技术参数

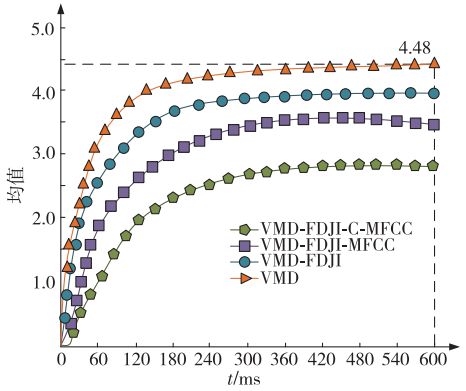
技术参数	数值
重量	250 kg
储能电机额定功率	2.5 kW
储能电机额定电压	380 V
合闸线圈额定电流	5 A
合闸线圈额定电压	220 V
分闸线圈额定电流	4 A
分闸线圈额定电压	220 V

为确保信号的真实性和可靠性，采用形态学滤波法将采集到的三种信号进行降噪处理，从而提取有效特征。将降噪处理后的三种信号按8∶2的比例划分为训练集与测试集，设置模态分解层数为4。首先以消融实验的方式验证了不同的模块对方法

整体性能的影响效果，图 7(a)与图 7(b)为四种模块在训练集和测试集中的均值测试结果。



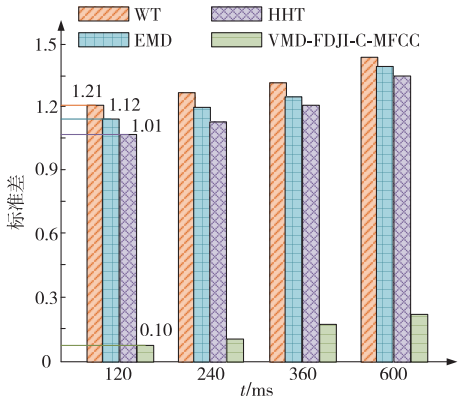
(a) 训练集



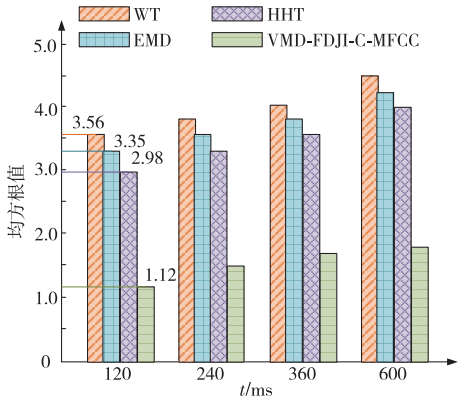
(b) 测试集

图 7　VMD-FDJI-C-MFCC 多源信号特征提取方法消融测试结果

由图 7 可知，单独的 VMD 模块在振动信号、声音信号以及电流信号特征提取任务中的表现并不理想，训练集及测试集中的均值分别达到了 4.43 与 4.48，表明该模块提取的特征存在较大的偏移。引入改进措施和融合 C-MFCC 模块后，算法的特征提取性能得到显著增强。在训练集与测试集中，VMD-FDJI-C-MFCC 算法的信号特征提取均值分别为 2.66 和 2.52。综上所述，研究提出的每一部分模块组成都对最终算法存在正向影响，能够有效提高多源信号特征提取效果。同时，研究还引入同类型的信号特征提取方法，即经验模态分解(Empirical Mode Decomposition, EMD)方法、小波变换(Wavelet Transform, WT)以及希尔伯特-黄变换法(Hilbert-Huang Transform, HHT)，以标准差和均方根值为参考指标进行对比测试。图 8(a)与图 8(b)为不同特征提取方法在正常工况下的信号标准差和均方根值。



(a) 标准差



(b) 均方根值

图 8　特征提取误差率和提取耗时

由图 8(a)可知，在正常工况下，所提出 VMD-FDJI-C-MFCC 多源信号特征提取方法能够更准确地提取信号的主要特征，且波动较小、表现更为稳定。EMD，WT，HHT 以及 VMD-FDJI-C-MFCC 信号特征提取标准差分别为 1.12，1.21，1.01 与 0.10。由图 8(b)可知，在正常工况下，所提出 VMD-FDJI-C-MFCC 多源信号特征提取方法能够在提取过程中更有效地减少噪声，提高信号的能量提取准确性。EMD，WT，HHT 以及 VMD-FDJI-C-MFCC 信号特征提取均方根值分别为 3.35，3.56，2.98 与 1.12。验证了 VMD-FDJI-C-MFCC 方法在多源信号特征提取与噪声抑制中的有效性。

2.2　主电网断路器异常监测与诊断方法仿真测试

将振动信号、声音信号以及电流信号的主成分融合特征参数输入强化分类器，共计获得 360 组数据。这些数据涵盖了四种典型的断路器状态，包括正常状态、螺丝松动状态、弹簧输出异常状态和电磁铁松动状态。其中，80 组为正常状态，140 组为螺丝松动，70 组为弹簧异常，70 组为电磁铁松动。为便于分类，四种状态分别用①，②，③和④进行标

记。在这360组特征数据中，选取280组数据用于训练，其中每种状态下随机选择70组数据进行训练，剩余的80组数据则用于测试。单一信号时的测试结果如表2所示。

表2 单一信号时的测试结果

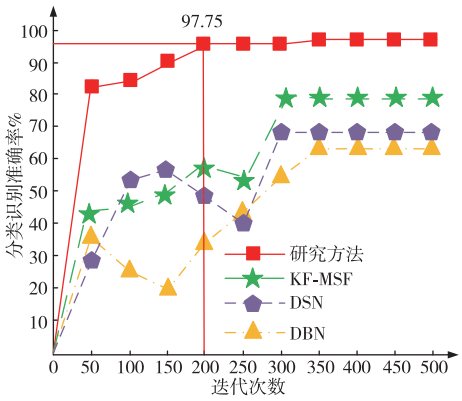
信号类别	工况	诊断结果				总正确率/%
		①	②	③	④	
振动信号	①	8	0	1	0	88.9
	②	0	8	0	1	
	③	0	0	8	1	
	④	1	0	0	8	
声音信号	①	8	1	0	1	90.0
	②	0	9	1	0	
	③	1	0	9	0	
	④	0	1	0	9	
电流信号	①	9	0	1	0	90.0
	②	1	9	0	0	
	③	0	0	9	1	
	④	0	1	0	9	

由表2可知，当使用单一信号时，KPCA-SVM-AWOA-XGBoost在不同信号下的诊断结果均表现良好。四种工况下的正确率均大于85%。总体来看，电流和声音信号的诊断效果略优于振动信号，但所有信号的总正确率均保持在较高水平，表明KPCA-SVM-AWOA-XGBoost在单一信号下的诊断性能较为稳定和可靠。联合信号时的测试结果如表3所示。

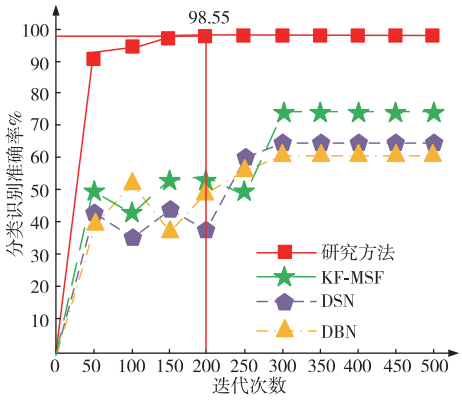
表3 联合信号时的测试结果

信号类别	工况	诊断结果				总正确率/%
		①	②	③	④	
振动-声音信号	①	9	0	0	1	90.0
	②	1	0	9	0	
	③	1	9	0	0	
	④	0	0	0	10	
声音-电流信号	①	0	10	0	0	90.0
	②	0	0	9	0	
	③	8	1	1	0	
	④	0	0	0	10	
电流-振动信号	①	0	0	10	0	87.5
	②	9	1	0	0	
	③	1	0	1	8	
	④	1	9	0	0	
振动-声音-电流信号	①	10	0	0	0	95.0
	②	1	9	0	0	
	③	0	10	0	0	
	④	1	9	0	0	

由表3可知，当使用联合信号时，KPCA-SVM-AWOA-XGBoost的诊断效果显著提升。对于不同信号组合，四种工况的正确率均达到了87%以上。联合信号的使用显著提高了诊断的准确性和稳定性，尤其是振动-声音-电流信号组合在所有工况下均表现出了优异的诊断性能。研究还引入了流行的电网异常监测与诊断方法，即卡尔曼滤波与多传感器融合（Kalman Filtering and Multi-sensor Fusion，KF-MSF）、分布式传感器网络（Distributed Sensor Network，DSN）以及深度置信网络模型（Deep Belief Networks，DBN），以分类识别准确率为测试指标进行了对比测试，图9(a)与图9(b)为不同方法在训练集和测试集中的测试结果。



(a) 训练集



(b) 测试集

图9 不同方法在训练集及测试集中的分类识别准确率结果

由图9可知，无论是在训练集中还是在测试集中，均是所提出的KPCA-SVM-AWOA-XGBoost断路器异常监测与诊断方法性能表现最佳。DBN，DSN，KF-MSF以及研究方法的最高分类识别准确率分别为62.2%，68.6%，76.8%与98.55%。究其原因在于KPCA和SVM的优势，提升了分类器对异常状态的识别能力。此外，AWOA和XGBoost

算法的融合进一步优化了算法性能。这些综合设计促使研究方法能够有效识别和处理复杂的多源数据，从而在主电网断路器异常分类识别任务中实现高精度的识别结果。

3　结束语

本文首先提出一种基于VMD-FDJI-C-MFCC的多源信号特征提取方法，并引入KPCA方法，以融合各特征参量来提高特征质量。在这些方法的基础之上，结合AWOA，SVM以及XGBoost，最终提出一种新型的基于KPCA-SVM-AWOA-XGBoost的断路器异常监测与诊断方法。实验结果表明，与其他信号特征提取方法相比，VMD-FDJI-C-MFCC性能表现最佳。该算法在训练集中的信号特征提取均值为2.66，而在测试集中则为2.52。此外，当使用单一信号时，KPCA-SVM-AWOA-XGBoost在不同信号下的诊断结果均表现良好。四种工况下的正确率均大于88%；而当使用联合信号时，四种工况下的正确率也均大于87%。由此可知，研究方法可实现对电网调控行为异常的监测与诊断。特别是在复杂环境中，该方法能够有效应对信号干扰和数据不完整等问题，从而提升监测和故障诊断的可靠性和智能化水平。然而，本研究仅对四种工况进行了探讨，未来可引入更多的故障类型进行分析，从而提高研究的全面性。

参考文献：

[1] 李可萌，陈富国，杨　晖，等. 基于姿态传感器的高压隔离开关机械故障智能诊断研究[J]. 电网技术，2023，47(9)：3781-3790.
Li Kemeng，Chen Fuguo，Yang Hui，et al. Intelligent diagnosis for mechanical faults of high voltage disconnector based on attitude sensor[J]. Power System Technology，2023，47(9)：3781-3790.

[2] 张　逸，黄佳铭，林鸿伟，等. 基于多源数据融合的省级电网电压暂降互动平台[J]. 电力自动化设备，2023，43(3)：196-203.
Zhang Yi，Huang Jiaming，Lin Hongwei，et al. Voltage sag interactive platform of provincial power grid based on multi-source data fusion[J]. Electric Power Automation Equipment，2023，43(3)：196-203.

[3] Ke Y，Chen H，Liu Z，et al. Perception and early warning technology of power substation safety construction operation based on multi-dimensional information fusion [J]. International Journal of Wireless and Mobile Computing，2024，26(4)：408-415.

[4] Tao L，Liu H，Zhang J，et al. Associated fault diagnosis of power supply systems based on graph matching：a knowledge and data fusion approach[J]. Mathematics，2022，10(22)：4306.

[5] Yang X，Jiang A，Jiang W，et al. Abnormal detection and fault diagnosis of adjustment hydraulic servomotor based on genetic algorithm to optimize support vector data description with negative samples and one-dimensional convolutional neural network[J]. Machines，2024，12(6)：368.

[6] 高艺文，苏学能，张　华，等. 基于数据校核与图卷积神经网络的高容错配电网故障诊断方法[J]. 电工电能新技术，2024，43(2)：95-104.
Gao Yiwen，Su Xueneng，Zhang Hua，et al. A highly fault-tolerant distribution network fault diagnosis method based on data check and graph convolution neural network[J]. Advanced Technology of Electrical Engineering and Energy，2024，43(2)：95-104.

[7] 王慧慧，李　超，陈　杰. 基于SSO优化VMD算法的齿轮箱状态监测及故障诊断[J]. 机械设计与研究，2022，38(6)：90-93.
Wang Huihui，Li Chao，Chen Jie. State monitoring and fault diagnosis of gearbox based on SSO optimization VMD algorithm[J]. Machine Design & Research，2022，38(6)：90-93.

[8] Lv L，Wu Z，Zhang J，et al. A VMD and LSTM based hybrid model of load forecasting for power grid security[J]. IEEE Transactions on Industrial Informatics，2022，18(9)：6474-6482.

[9] Wang X，Li X，Wang J，et al. Short-term power grid load forecasting based on optimized VMD and GA-BP [J]. International Journal of Low-Carbon Technologies，2024，19：980-986.

[10] Sun Q，Cai H. Short-term power load prediction based on VMD-SG-LSTM[J]. IEEE Access，2022，10：102396-102405.

[11] 牛　博，王雪莉，吴　兵，等. 基于运动轨迹检测与支持向量机的高压断路器机械缺陷诊断方法[J]. 高压电器，2024，60(8)：29-36.
Niu Bo，Wang Xueli，Wu Bing，et al. Mechanical defect detection method of high voltage circuit breaker based on motion trajectory detection and support vector machine[J]. High Voltage Apparatus，2024，60(8)：29-36.

[12] 姚聪伟，庞小峰，孙　帅，等. 基于二次时间信息的断路器操动机构状态预警方法研究[J]. 高压电器，2022，58(11)：114-120.
Yao Congwei，Pang Xiaofeng，Sun Shuai，et al. Research on state warning method of operating mechanism for circuit breaker based on secondary time information [J]. High Voltage Apparatus，2022，58(11)：114-120.

[13] Wang Z，He X，Shen H，et al. Multi-source information fusion to identify water supply pipe leakage based on SVM and

VMD[J]. Information Processing & Management, 2022, 59(2): 102819.

[14] 程 显, 余亚东, 葛国伟, 等. 混合式直流断路器状态感知技术与智慧框架体系探讨[J]. 电网技术, 2024, 48(7): 3033-3042.
Cheng Xian, Yu Yadong, Ge Guowei, et al. Hybrid DC circuit breaker states sensing technology and its intelligent framework system[J]. Power System Technology, 2024, 48(7): 3033-3042.

[15] 王 伟, 帅智康, 李 杨, 等. 基于固态断路器主动注入式直流故障测距方法[J]. 电工技术学报, 2024, 39(8): 2360-2370.
Wang Wei, Shuai Zhikang, Li Yang, et al. Active injection DC fault location method based on solid state circuit breaker[J]. Transactions of China Electrotechnical Society, 2024, 39(8): 2360-2370.

[16] 徐 军, 齐蓬勃, 李 凡, 等. 一种基于KPCA-IF的配电网保护系统异常状况监测模型[J]. 电力科学与技术学报, 2024, 39(3): 31-37.
Xu Jun, Qi Pengbo, Li Fan, et al. An anomaly detection method for protection relay system in distribution networks based on KPCA-IF models[J]. Journal of Electric Power Science and Technology, 2024, 39(3): 31-37.

[17] 刘可真, 姚 岳, 赵现平, 等. 基于样本集成学习和SO-SVM的变压器故障诊断[J]. 电机与控制应用, 2023, 50(12): 21-31.
Liu Kezhen, Yao Yue, Zhao Xianping, et al. Transformer fault diagnosis based on sample integration learning and SO-SVM[J]. Electric Machines & Control Application, 2023, 50(12): 21-31.

[18] 柯 亮, 李 波, 廖 凯, 等. 基于XGBoost的配电网高阻接地故障检测方法[J]. 电力系统保护与控制, 2024, 52(6): 88-98.
Ke Liang, Li Bo, Liao Kai, et al. High impedance fault detection method in a distribution network based on XGBoost[J]. Power System Protection and Control, 2024, 52(6): 88-98.

作者简介：

吴岳洲(1971—),男,广东省广州市人,高级工程师,主要研究方向为电力系统。