

DOI: 10.19650/j.cnki.cjsi.J2413080

# 基于空间运动特性的断路器健康状态识别\*

孙曙光<sup>1</sup>, 王浩宇<sup>1</sup>, 王景芹<sup>2</sup>, 李奎<sup>3</sup>, 郝永耀<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. 河北工业大学电工产品可靠性技术省部共建协同创新中心 天津 300130; 3. 河北工业大学省部共建电工装备可靠性与智能化国家重点实验室 天津 300130; 4. 江苏四方清洁能源装备制造有限公司 徐州 221000)

**摘要:**考虑到空间运动特性差异对机械性能退化的体现更为直接,且振动信号蕴含丰富的机械状态信息,提出一种利用振动信号对空间运动特性进行表征的断路器健康状态识别方法。首先,利用位移信号获取能够反映关键机构机械状态的运动特性参数;其次,采用AAF-AAKR模型构建运动特性健康指标;然后,基于关键动作阶段三维振动信号特点提取多域特征参数,选取相关性较高的特征进行层次聚类并计算与运动特性的互信息,得到对运动特性表征能力强的关键退化特征矢量;最后,将退化特征矢量作为输入,运动特性健康指标作为输出,构建1D-CNN性能退化回归模型,以实现储能机构健康状态识别。实例验证表明,三维振动信号相对于一维振动信号对运动健康指标的拟合效果更好,回归分析RMSE为0.0186,MAE为0.0112,可精准地识别断路器的健康状态。

**关键词:** 万能式断路器; 三维振动信号; 空间运动特性; 健康状态识别

**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

## Circuit breaker health state identification based on spatial motion characteristics

Sun Shuguang<sup>1</sup>, Wang Haoyu<sup>1</sup>, Wang Jingqin<sup>2</sup>, Li Kui<sup>3</sup>, Hao Yongyao<sup>4</sup>

(1. School of Artificial Intelligence, Hebei University of Technology, Tianjin 300130, China; 2. Provincial and Ministerial Co-construction Collaborative Innovation Center on Reliability Technology of Electrical Products, Hebei University of Technology, Tianjin 300130, China; 3. State Key Laboratory of Reliability and Intelligence of Electrical Equipment, Hebei University of Technology, Tianjin 300130, China; 4. Jiangsu Sifang Clean Energy Equipment Manufacturing Co., Ltd., Xuzhou 221000, China)

**Abstract:** Considering that the difference in spatial motion characteristics is more direct to the mechanical property degradation, and the vibration signal contains rich mechanical state information, a circuit breaker health state identification method is proposed using vibration signals to characterize spatial motion properties. First, the displacement signal is used to obtain the motion characteristic parameters that can reflect the mechanical state of the key mechanism. Secondly, the AFF-AAKR is utilized to construct motion-characteristic health indicators offline. Then, multi-domain feature parameters are extracted based on the characteristics of the three-dimensional vibration signal in the key action phase. The features with higher correlation are selected for hierarchical clustering and the mutual information with the motion characteristics is calculated to achieve the key degradation feature vectors with strong characterization ability of the motion characteristics. Finally, the degradation feature vectors are used as the input and the health indicator of motion characteristics is used as the output to construct a 1D-CNN performance degradation regression model. In this way, the health state identification of the energy storage mechanism is realized. The example validation shows that the three-dimensional vibration signal fits the motion health indicator better than the one-dimensional vibration signal, and the regression analysis RMSE is 0.0186 and MAE is 0.0112, which can accurately identify the health status of the circuit breaker.

**Keywords:** conventional circuit breaker; three-dimensional vibration signal; spatial motion characteristics; health state identification

收稿日期: 2024-07-22 Received Date: 2024-07-22

\* 基金项目: 河北省中央引导地方科技发展资金(246Z2101G)、河北省自然科学基金创新群体(E2024202298)、河北省自然科学基金(E2021202136)项目资助

## 0 引言

随着国民经济的快速增长,电网的复杂度不断提高,万能式断路器作为低压配电系统中的关键设备,保持其在服役期内的稳定运行至关重要<sup>[1]</sup>。储能机构作为断路器的重要部件,其健康运行对提高断路器的可靠性具有重要意义<sup>[2]</sup>。随着操动次数的增加,断路器关键部件的机械性能会发生退化,如何准确有效地监测断路器机械特性的变化,识别健康状态是目前亟需解决的问题。

目前断路器的机械特性监测一般包含振动信号和位移信号。其中,振动信号蕴含了丰富的机械状态信息,基于振动信号识别断路器的机械状态取得了很好的效果<sup>[3-8]</sup>。文献[3]利用振动信号的优选泛特征,并结合 t-分布随机临近嵌入和 K 最近邻分类识别算法,实现了断路器弹簧机构储能状态辨识。文献[4]对振动信号进行自适应噪声集合经验模态分解后,在极坐标下定义谱形状熵,由分群粒子群优化-支持向量机实现断路器操动状态辨识。文献[5]采用连续小波变换处理振动信号,构建多任务学习深度残差网络模型识别断路器故障程度。但是以上对断路器的振动信号分析为一维振动模式,而三维振动信号能提供更全面的数据信息<sup>[9]</sup>。文献[10]基于三维振动信号对电机进行了多类故障诊断,利用三维特征集有效提高了诊断精度。文献[11]根据电机的三维振动特性,得到了不同工况下的振动规律,更全面的识别了电机故障。

相比于振动信号,位移信号更能直接反映断路器关键部件的实际运行状态,具有更强的可解释性,同样受到了学者们的广泛关注<sup>[12-14]</sup>。文献[12]根据断路器分合闸弹簧行程信号中蕴含的机械特性信息,引入了行程特征量,运用串行决策支持向量机分类弹簧故障。文献[13]分析了断路器内部机械部件的位移曲线,选取了能够反映操作机构性能的特征量进行实时监测,基于操作机构的运动特性实现了断路器机械特性状态监测。文献[14]通过采集断路器储能杠杆和联动轴的位移信号,基于空间形位偏差分析运动特性,研究了断路器关键零件的断裂失效过程。通过空间运动特性分析可以更为直接的阐明断路器关键机构的失效过程,所构建健康指标的物理可解释性更强,对退化过程的刻画更为完善,但受制于测量方式的制约,可操作性存在不足。

为实现振动信号对空间运动特性的表征,增加基于振动检测的退化过程分析的可解释性,需要将一维振动信号拓展至三维振动信号,并构建三维振动信号与基于空间运动特性获取的健康指标之间的映射关系。

利用位移信号可以实现运动特性的量化分析,但单一特性参数包含的退化信息有限<sup>[15]</sup>,而融合不同的特性

参数构建健康指标能够更全面反映断路器机械性能退化状态。对于断路器这种机械机构复杂的系统而言,特性参数具有非线性以及参数间存在差异性,因而需要自适应捕捉各特性参数的局部退化信息,自适应特征融合(adaptive feature fusion, AFF)基于线性加权和动态权重原理,在构造健康指标时能够很好的应对特性参数的局部变化<sup>[16]</sup>。此外由于故障数据的不确定性和变化性,所以健康状态下的数据对健康指标的构建至关重要,自联想核回归(auto association kernel regression, AAKR)是一种非参数建模方法<sup>[17]</sup>,通过计算观测向量和健康空间向量的相似度来修正当前观测向量的偏差,能够一定程度上抑制异常数据对整体健康指标的影响<sup>[18]</sup>。

获取健康指标后,若直接利用原始振动信号映射健康指标会对模型带来时间消耗和记忆压力的问题,需要对原始振动信号进行特征提取和筛选<sup>[19]</sup>。对于特征提取,振动信号的时域和频域蕴含了大量的状态信息<sup>[20]</sup>,且时频域分析可以发现信号中微小短促异常<sup>[21]</sup>,故可以提取三维振动信号的时域、频域和时频域多域特征。对于特征筛选,斯皮尔曼秩相关系数法因计算复杂度低,鲁棒性高,同时具有普适性和公平性的特点,被广泛应用于特征选择<sup>[22]</sup>。此外,采用层次聚类法和最大信息系数法进行特征选择也引起了学者们的关注<sup>[23-24]</sup>,文献[23]基于斯皮尔曼相关性和层次聚类去除冗余,选取了能够反映电网动态频率的关键特征,缩短了预测算法训练时间。文献[24]利用互信息度量特征间的差异性,结合特征和标签的相关性构造了评价函数,实现了特征约简。因而可设计多重特征选择方法,采用斯皮尔曼秩相关系数以及层次聚类分析,消除冗余获得相对独立的振动特征,并结合特征与健康指标间的互信息获得关键退化特征。在此基础上构建关键振动特征和运动特性健康指标的映射关系进行性能退化分析,以实现断路器健康状态的识别。对此,需要充分挖掘振动特征的深层次信息用于性能退化回归分析,深度学习中的卷积神经网络(convolutional neural network, CNN)在回归分析中表现良好,可用来构建性能退化回归模型<sup>[25-27]</sup>。

综上,本文立足于储能机构的位移和三维振动信号检测,提出一种基于空间运动特性的断路器健康状态识别方法。利用位移信号获取能够直接反映机构空间运动状态的运动特性参数,并提出 AFF-AAKR 模型,以达到在降低计算复杂度、减少异常数据影响的同时,构建包含更多局部退化信息的运动特性健康指标。并提取储能机构关键动作阶段三维振动信号的多域特征信息,采用多重特征选择方法得到关键退化特征参数。进而构建一维卷积神经网络(1-dimensional convolutional neural network, 1D-CNN)拟合关键退化特征和运动特性健康指标的映射关系,实现储能机构健康状态的识别。

# 1 断路器储能机构健康状态识别方法

本文基于三维振动信号表征储能机构空间运动特性从而识别断路器的健康状态,具体流程如图1所示。

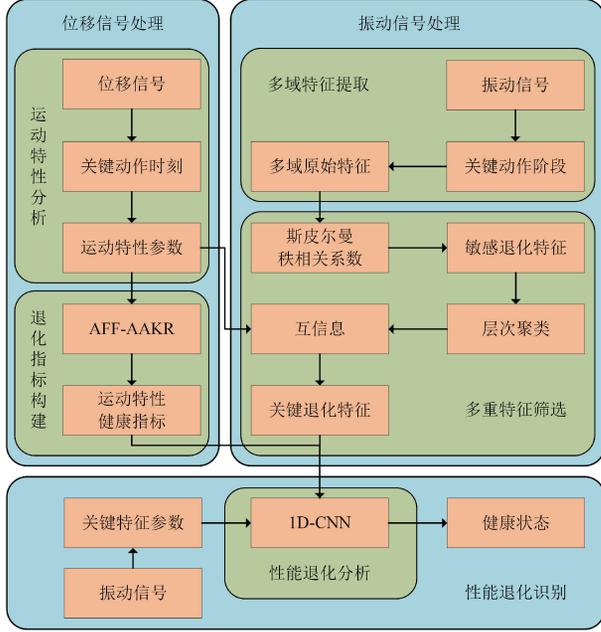


图1 健康状态识别流程

Fig.1 The overall process of health state identification

**位移信号处理:**利用储能机构的位移信号获得关键动作时刻,并根据储能机构运动原理分析机构的空间运动特点,从而选取能够反映关键部件退化性能的运动特性参数。采用自适应特征融合-自联想核回归模型的综合方法对运动特性参数融合,构建运动特性健康指标。

**振动信号处理:**分析储能机构关键动作阶段的三维振动信号特点,提取时域、频域和时频域的多域原始特征。利用斯皮尔曼秩相关系数选取与断路器动作次数相关性较强的敏感退化特征,层次聚类后计算各特征与运动特性的互信息,经多重特征筛选后得到表征运动特性能力强的关键退化特征。

**性能退化识别:**将关键退化特征作为输入,运动特性健康指标作为输出,利用1D-CNN构建两者之间的映射关系得到性能退化回归模型,基于振动信号的特征参数识别断路器储能机构的性能退化状态。

## 1.1 运动特性健康指标构建

构建运动特性健康指标是健康状态识别的重要环节,本文提出了一种基于自适应特征融合和自联想核回归模型的健康指标构建方法。该方法结合了自适应特征融合在特征轴上低复杂度压缩以及自联想核回归在时间轴上定量比较的优点,可以获取性能更高的健康指标。

## 1) AFF方法

设基于位移信号获得  $K$  个能够反映储能机构空间运动特性的向量  $\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_K$ , 其中断路器的动作次数  $N$  作为向量的长度。则利用该向量组成的运动特性矩阵  $\mathbf{Z}_{N \times K}$  为:

$$\mathbf{Z}_{N \times K} = [\mathbf{Z}_1 \mathbf{Z}_2 \dots \mathbf{Z}_K] = \begin{bmatrix} z_{11} & \dots & z_{1K} \\ \vdots & \ddots & \vdots \\ z_{N1} & \dots & z_{NK} \end{bmatrix} \quad (1)$$

在  $t$  时刻,第  $i$  个特性参数的值为  $z_{it} (t = 1, 2, \dots, N; i = 1, 2, \dots, K)$ , 该特性参数与所有其他特性参数之间的平均距离  $d_i(z_{it})$  为:

$$d_i(z_{it}) = \frac{1}{K-1} \sum_{i \neq j}^K (z_{it} - z_{jt})^2 \quad (2)$$

具有最小距离  $d_i$  的特性参数  $z_{it}$  与其他特性参数  $z_{it} (i \neq j)$  的相关性最大,应该给予较大的权重。 $z_{it}$  分配到的权重  $\omega_{it}$  为:

$$\omega_{it} = e^{-d_i(z_{it})} \quad (3)$$

分配给每个特性参数的权重  $\omega_{it}$  根据距离  $d_i(z_{it})$  的大小而自适应变化,因此基于自适应特征融合的  $t$  时刻运动特性健康指标  $F_{\text{inal}}(t)$  为:

$$F_{\text{inal}}(t) = \frac{\sum_{i=1}^K \omega_{it} z_{it}}{\sum_{i=1}^K \omega_{it}} \quad (4)$$

## 2) AFF-AAKR模型

通过自适应特征融合将运动特性矩阵压缩为一维向量后,利用自联想核回归对压缩后的向量融合。该方法在特征轴上对运动特性矩阵进行压缩,在时间轴上进行定量比较,同时解决了自联想核回归耗时过长的问题。

基于自适应特征融合压缩运动特性矩阵  $\mathbf{Z}_{N \times K}$  得到一维观测向量  $\mathbf{Z}_N^{\text{obs}}$  为:

$$\mathbf{Z}_N^{\text{obs}} = [F_{\text{inal}}(1), F_{\text{inal}}(2), \dots, F_{\text{inal}}(N)]^T \quad (5)$$

认为断路器的前  $h$  次动作为健康状态,将观测向量  $\mathbf{Z}_N^{\text{obs}}$  的前  $h$  个元素作为健康空间向量  $\mathbf{H}_{\text{ealth}}$ :

$$\mathbf{H}_{\text{ealth}} = [H_{\text{ealth}}(1), H_{\text{ealth}}(2), \dots, H_{\text{ealth}}(h)]^T = [F_{\text{inal}}(1), F_{\text{inal}}(2), \dots, F_{\text{inal}}(h)]^T \quad (6)$$

在  $t$  时刻,观测向量  $\mathbf{Z}_N^{\text{obs}}$  的元素  $F_{\text{inal}}(t)$  与健康空间向量中第  $j$  个元素  $H_{\text{ealth}}(j)$  之间的距离为:

$$d_j(F_{\text{inal}}(t), H_{\text{ealth}}(j)) = |F_{\text{inal}}(t) - H_{\text{ealth}}(j)| \quad (7)$$

通过径向基函数计算  $t$  时刻观测向量中元素  $F_{\text{inal}}(t)$  与健康空间向量中第  $j$  个元素  $H_{\text{ealth}}(j)$  之间的权重  $\omega_j$ :

$$\omega_j = K_h(d_j) = \frac{1}{\sqrt{2\pi}h^2} e^{-\frac{d_j^2}{2h^2}} \quad (8)$$

$t$  时刻观测向量中元素  $F_{\text{inal}}(t)$  的期望为  $\hat{F}_{\text{inal}}(t)$ , 即健康空间向量  $\mathbf{H}_{\text{ealth}}$  中所有元素的加权平均。最终将

$F_{\text{inal}}(t)$  和  $\hat{F}_{\text{inal}}(t)$  之间的绝对距离作为  $t$  时刻最终的健康指标  $HI(t)$ :

$$HI(t) = |F_{\text{inal}}(t) - \hat{F}_{\text{inal}}(t)| = \left| F_{\text{inal}}(t) - \frac{\sum_{j=1}^h (\omega_j H_{\text{ealth}}(j))}{\sum_{j=1}^h \omega_j} \right| \quad (9)$$

1.2 多域特征提取

1) 时域特征提取

时域特征计算简单、趋势明显,能够表征机构健康状况相关信息,不同参数表征程度有所区别。设长度为  $L$  的振动信号  $\mathbf{x} = [x_1, x_2, \dots, x_L]$ , 则常用的时域特征及计算公式如表 1 所示。

表 1 时域特征计算方法

Table 1 Calculation of time-domain features

特征参数	计算公式	特征参数	计算公式
均值	$\bar{x} = \frac{1}{L} \sum_{i=1}^L x_i$	有效值	$x_{\text{rms}} = \sqrt{\frac{1}{L} \sum_{i=1}^L x_i^2}$
标准差	$x_{\text{std}} = \sqrt{\frac{1}{L} \sum_{i=1}^L (x_i - \bar{x})^2}$	峰峰值	$\max\{x_i\} - \min\{x_i\}$
偏度	$\frac{\sum_{i=1}^L (x_i - \bar{x})^3 / Lx_{\sigma}^3}{\sum_{i=1}^L (x_i - \bar{x})^3 / Lx_{\sigma}^3}$	峰值指标	$\max\{ x_i \} / x_{\text{rms}}$
波形指标	$x_{\text{rms}} / \frac{1}{L} \sum_{i=1}^L  x_i $	裕度指标	$\frac{\max\{ x_i \}}{\left(\frac{1}{L} \sum_{i=1}^L  x_i \right)^2}$
脉冲指标	$\frac{\max\{ x_i \}}{\frac{1}{L} \sum_{i=1}^L  x_i }$		

均值可以反映振动强度变化;有效值反映振动能量变化;标准差反映振动离散程度变化;峰峰值反映振动幅值变化;偏度反映振动非周期性变化;峰值指标反映最大运动范围变化;波形指标反映波形与标准正弦波的差异变化;裕度指标可以反映振动偏离变化;脉冲指标可以反映振动冲击强度变化。因此,综合提取各特征参数可反映储能机构的性能变化。

2) 频域特征提取

振动信号频域分析可描述频谱中不同频率成分的分布,反映机构的健康程度。振动信号经傅里叶变换的频谱  $\mathbf{f} = [f_1, f_2, \dots, f_M]$  ( $M = L/2$ ), 则频域特征计算如表 2 所示。

频谱参数反映振动信号能量变化,频率参数反映频谱变化,不同参数对机构健康状态反映程度和敏感程度不同,因此对频域特征综合提取。

3) 时频域特征提取

表 2 频域特征计算方法

Table 2 Calculation of frequency-domain features

特征参数	计算公式	特征参数	计算公式
频谱均值	$\bar{f} = \frac{1}{M} \sum_{i=1}^M f_i$	频谱有效值	$\sqrt{\frac{1}{M} \sum_{i=1}^M f_i^2}$
频谱标准差	$f_{\sigma} = \sqrt{\frac{1}{M} \sum_{i=1}^M (f_i - \bar{f})^2}$	频谱偏度	$\sum_{i=1}^M (f_i - \bar{f})^3 / Mf_{\sigma}^3$
频率重心	$F_o = \frac{\sum_{i=1}^M if_i}{\sum_{i=1}^M f_i}$	频率有效值	$\sqrt{\frac{\sum_{i=1}^M (i^2 f_i)^2}{\sum_{i=1}^M f_i}}$
频率标准差	$F_{\sigma} = \sqrt{\frac{\sum_{i=1}^M (i - F_o)^2 f_i}{\sum_{i=1}^M f_i}}$	频率偏度	$\sum_{i=1}^M \left[ \frac{(i - F_o)^3 f_i}{\sum_{i=1}^M f_i} \right]$
频谱变异系数	$F_{\sigma} / F_o$		

时域和频域分析不能观察到频率随时间的变化关系,基于小波变换的小波包分解不仅表征低频信号特性,还再划分了信号的高频成分,能够对信号进行更好的时频局部化分析。将小波包和能量熵结合,提取能够反映振动信号状况的小波包能量熵值。设分解后第  $j$  层第  $k$  个小波包节点为  $s_{(j,k)}$ , 其长度与原始信号数据长度相同为  $L$ , 则该小波包节点中各点的测度  $\varepsilon_{(j,k)}(i)$  为:

$$\varepsilon_{(j,k)}(i) = \frac{(s_{(j,k)}(i))^2}{\sqrt{\sum_{i=1}^L (s_{(j,k)}(i))^2}} \quad (10)$$

根据信息熵的理论,第  $j$  层第  $k$  个小波包能量熵  $E_{(j,k)}$  为:

$$E_{(j,k)} = - \sum_{i=1}^L \varepsilon_{(j,k)}(i) \lg \varepsilon_{(j,k)}(i) \quad (11)$$

1.3 多重特征筛选方法

1) 斯皮尔曼秩相关系数

斯皮尔曼秩相关系数用来估计两个变量之间的相关性,对储能机构振动信号所提取的非平稳多域特征具有良好的适用性。假设两个变量  $\mathbf{X} = [X_1, X_2, \dots, X_N]$  和  $\mathbf{Y} = [Y_1, Y_2, \dots, Y_N]$ , 其中  $N$  为变量的元素个数,  $X_i, Y_i$  为变量中第  $i$  个元素 ( $1 \leq i \leq N$ )。分别对  $\mathbf{X}, \mathbf{Y}$  进行降序编秩得到元素排行集合  $\mathbf{S}$  和  $\mathbf{T}$ ,  $X_i$  在  $\mathbf{X}$  的排序以及  $Y_i$  在  $\mathbf{Y}$  中的排序分别用  $S_i, T_i$  表示。则变量  $\mathbf{X}$  和  $\mathbf{Y}$  的斯皮尔曼秩相关系数  $\rho$  为:

$$\rho = 1 - \frac{6 \sum_{i=1}^N (S_i - T_i)^2}{N(N^2 - 1)} \quad (12)$$

两变量的斯皮尔曼秩相关系数的值在  $[-1, 1]$  之间,

当  $|\rho| \leq 0.2$  时, 变量呈极弱相关或不相关; 当  $0.2 < |\rho| \leq 0.4$  时, 变量呈弱相关; 当  $0.4 < |\rho| \leq 0.6$  时, 变量呈中等程度相关; 当  $0.6 < |\rho| \leq 0.8$  时, 变量呈强相关; 当  $0.8 < |\rho| \leq 1$  时, 变量呈极强相关。

## 2) 层次聚类

层次聚类是一种常用的无监督聚类方法, 通过最小化类间距离和最大化类内距离来划分簇。层次聚类算法根据层次分解的顺序可分为自下向上的凝聚法和自上向下的分裂法, 本文采用凝聚法进行层次聚类。

假设多域原始特征经过斯皮尔曼秩相关系数法筛选后得到包含  $Q$  个特征的特征集合  $\{F_1, F_2, \dots, F_Q\}$ , 对特征集合进行层次聚类, 得到包含不同特征的  $R$  个簇  $\{C_1, C_2, \dots, C_R\}$ 。

将特征集合  $\{F_1, F_2, \dots, F_Q\}$  中的每个特征  $F_i$  都看作一个独立的类, 即  $\{C_1, C_2, \dots, C_Q\}$ 。计算每两类之间的距离并把距离最近的两个类  $C_i$  和  $C_j$  合并为一个新类, 重复该步骤直到所有类最后合并为一类, 最终依据设定的距离阈值得到最终的  $R$  个簇  $\{C_1, C_2, \dots, C_R\}$ 。

## 3) 基于互信息的特征选择

为了消除冗余, 根据特征的相似性分为几个簇, 用每个簇中包含信息最多的特征替换该簇, 信息可以用互信息来度量。

设第  $i$  个特征  $F_i$  的边缘概率分布函数为  $p(F_i)$ , 则  $F_i$  在分布中的不确定性用信息熵  $H(F_i)$  表示:

$$H(F_i) = - \sum_{F_i} p(F_i) \log p(F_i) \quad (13)$$

基于位移信号获取的运动特性向量集合为  $Z = \{Z_1, Z_2, \dots, Z_K\}$ , 在已知运动特性  $Z_j$  后, 设特征  $F_i$  的条件概率分布函数为  $p(F_i | Z_j)$ , 则  $F_i$  的不确定性可用条件熵  $H(F_i | Z_j)$  表示:

$$H(F_i | Z_j) = - \sum_{Z_j} p(Z_j) \sum_{F_i} p(F_i | Z_j) \log p(F_i | Z_j) \quad (14)$$

则特征  $F_i$  和向量  $Z_j$  之间的互信息计算为:

$$I(F_i; Z_j) = H(F_i) - H(F_i | Z_j) = I(Z_j; F_i) \quad (15)$$

互信息是信息熵和条件熵之间的差值, 意味着两个特征之间的相互依赖程度。每个簇中各特征  $F_i$  与运动特性向量集合  $Z = \{Z_1, Z_2, \dots, Z_K\}$  间的平均互信息为:

$$Rel(F_i) = \frac{1}{K} \sum_{j=1}^K I(F_i; Z_j) \quad (16)$$

选取平均互信息最大的特征  $F_{\max}(r)$  作为该簇  $C_r$  最具代表性的特征:

$$F_{\max}(r) = \max_{F_i \in C_r} \{Rel(F_i)\} \quad (17)$$

将各簇  $C_r$  中包含运动特性信息最多的特征  $F_{\max}(r)$  作为保留特征, 构成多重特征选择后的关键退化特征集合  $\{F_{\max}(1), F_{\max}(2), \dots, F_{\max}(R)\}$ 。

## 1.4 1D-CNN 回归模型

CNN 模型可通过卷积和池化操作挖掘数据的高维特征, 典型 CNN 通常用来处理二维数据, 而经过多重特征选择后的断路器关键退化特征为  $R \times 1$  的一维数据, 故本文选用 1D-CNN 模型进行回归分析。

输入层为  $R \times 1$  的断路器关键特征构成的数值矩阵。卷积层通过移动卷积核提取上一层输出的特征向量, 通过堆叠多个卷积核来挖掘数据的深层微小特征。卷积层的公式如下:

$$a_j^l = \xi \left( \sum_{i=1}^s a_i^{l-1} * k_{ij}^l + b_j^l \right) \quad (18)$$

其中,  $a_j^l$  是第  $l$  层输出的第  $j$  个特征向量,  $a_i^{l-1}$  是第  $l$  层输入的第  $i$  特征向量,  $k_{ij}^l$  是第  $l$  层的卷积核,  $b_j^l$  是第  $l$  层的偏置。  $s$  是第  $l$  层的输入征向量个数,  $*$  是卷积。  $\xi$  是激活函数, 其中 Relu 函数具有计算量小、学习率快的优点, 选其作为激活函数, 计算如下:

$$\xi(a) = \max(a, 0) \quad (19)$$

池化层对卷积层输出的特征向量约简, 从而减少参数的数量和计算复杂度, 控制过拟合的同时降低卷积对边缘的敏感程度。最大池化公式如下:

$$P_i^{l+1}(j) = \max_{(j-1)V+1 \leq s \leq jV} \{q_i^l(s)\} \quad (20)$$

其中,  $P_i^{l+1}(j)$  是第  $l+1$  层神经元值,  $q_i^l(s)$  是第  $s$  层第  $s$  个特征向量,  $V$  是池化区域的宽度。

全连接层将卷积和池化操作后的特征进行整合以及进一步提取, 最终得到模型的回归结果。公式表达如下:

$$y = \sigma(\omega \times a + b) \quad (21)$$

其中,  $y$  是全连接层输出向量,  $\sigma$  是激活函数,  $\omega$  是权重矩阵,  $a$  为全连接层输入向量,  $b$  为偏置向量。

为了评估模型的精度, 本文选取度量拟合优度的可决系数 (coefficient of determination,  $R^2$ )、均方根误差 (root mean square error, RMSE) 和平均绝对误差 (mean absolute error, MAE) 作为模型评价指标, 公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^{\lambda} (y_i - \hat{y}_i)^2}{\sum_{i=1}^{\lambda} (y_i - \bar{y})^2} \quad (22)$$

$$RMSE = \sqrt{\frac{1}{\lambda} \sum_{i=1}^{\lambda} (\hat{y}_i - y_i)^2} \quad (23)$$

$$MAE = \frac{1}{\lambda} \sum_{i=1}^{\lambda} |\hat{y}_i - y_i| \quad (24)$$

其中,  $\lambda$  是测试样本容量,  $\hat{y}_i$  为第  $i$  个运动特性健康指标预测值,  $y_i$  是第  $i$  个运动特性健康指标实际值,  $\bar{y}$  是运动特性健康指标实际值的均值。

## 2 断路器机械特性试验系统

本文以 DW15-1600 断路器作为试品, 同时搭建了断

断路器机械特性试验系统。系统由 3 个模块组成,包含虚拟仪器模块、逻辑控制模块和数据采集模块。上位机中的虚拟仪器 LabVIEW 通过 ISA 总线与 PCL-720 板卡进行通信,板卡输出逻辑电平控制选相板的通断,进而控制断路器欠压、储能、合闸和分闸动作。利用 WDD35D4 电阻型角位移传感器和 1A302E 三向压电式加速度传感器检测储能过程中方轴的角位移和振动信号,由 DH5922D 动态信号测试分析系统以 256 kHz 采样速率进行数据采集,并上传到上位机进行显示和存储,采集时间为 1.5 s。试验平台及传感器的安装如图 2 所示。断路器在 1 800 次动作后由于方轴的损坏发生卡涩,认为储能机构机械失效。

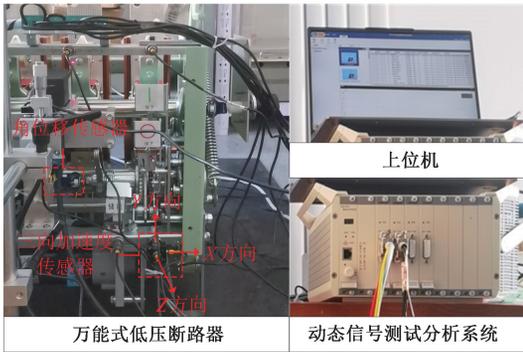


图 2 断路器机械特性试验平台

Fig. 2 Circuit breaker mechanical characteristics test platform

### 3 运动特性分析及健康指标构建

#### 3.1 储能机构空间运动特性分析

断路器储能机构示意图和实物如图 3 所示,主要机构包括储能电机、传动机构和弹簧机构。从能量传递的角度出发,储能电机的能量通过连杆和掣子推动方轴传递到储能弹簧中保存。因此,传动机构中方轴的运动是储能过程中最关键的能量传递环节,方轴在运动过程中会发生磨损和形变,使储能机构的空间运动特性改变。

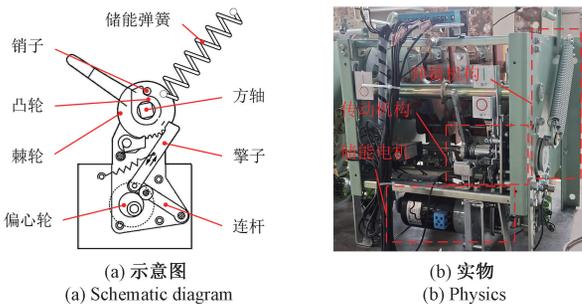


图 3 断路器储能机构

Fig. 3 Circuit breaker energy storage mechanism

检测断路器在储能过程中方轴的运动位移信号,绘制位移-时间曲线如图 4 所示。位移信号凸显了储能过程中方轴的空间运动关系,以  $t_1$ 、 $t_2$ 、 $t_3$ 、 $t_4$  标定方轴转动开始时刻、位移最大时刻、反向回弹最大时刻和回弹结束时刻,如表 3 所示。

表 3 方轴关键动作时刻

Table 3 Critical action moments of the square axes

特征时刻	名称	时间/ms	角度/(°)
$t_1$	转动开始时刻	622.1	0.00
$t_2$	位移最大时刻	1 152.5	176.69
$t_3$	反向回弹最大时刻	1 153.3	175.48
$t_4$	回弹结束时刻	1 155.7	175.74

由图 4 可以看出方轴运动包含角度逐渐增加的转动过程和角度逐渐衰减的回弹过程。

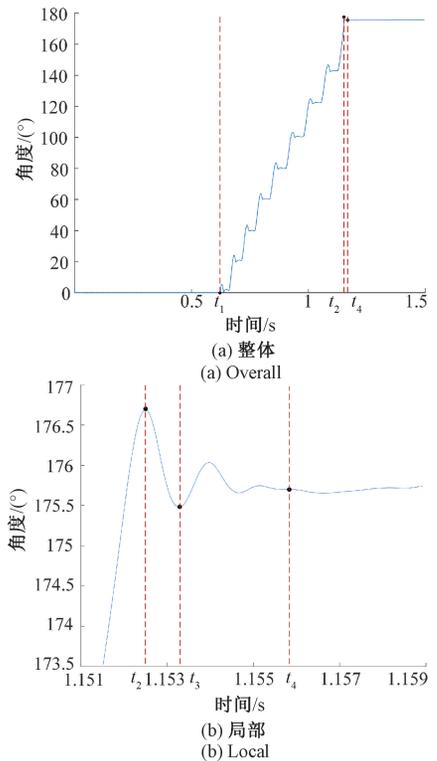


图 4 方轴运动位移-时间曲线

Fig. 4 Displacement-time curve of square-axis motion

选取能够反映储能机构空间运动特性的 4 个特征量:转动速度、形位偏差、回弹程度和回弹时间,分别用  $Z_1$ 、 $Z_2$ 、 $Z_3$  和  $Z_4$  表示。如表 4 所示,其中  $\alpha_1$ 、 $\alpha_2$ 、 $\alpha_3$ 、 $\alpha_4$  为  $t_1$ 、 $t_2$ 、 $t_3$ 、 $t_4$  时刻对应的角度,  $\alpha_2$  为断路器健康状态下前 300 次动作的  $\alpha_2$  平均值。

运动特性变化如图 5 所示。可以发现随着断路器动

表4 储能过程方轴运动特性

Table 4 Motion characteristics of energy storage process

运动特性	特征量	计算公式
转动速度	$Z_1$	$(\alpha_2 - \alpha_1)/(t_2 - t_1)$
形位偏差	$Z_2$	$\alpha_2 - \alpha_2$
回弹程度	$Z_3$	$\alpha_2 - \alpha_3$
回弹时间	$Z_4$	$t_4 - t_2$

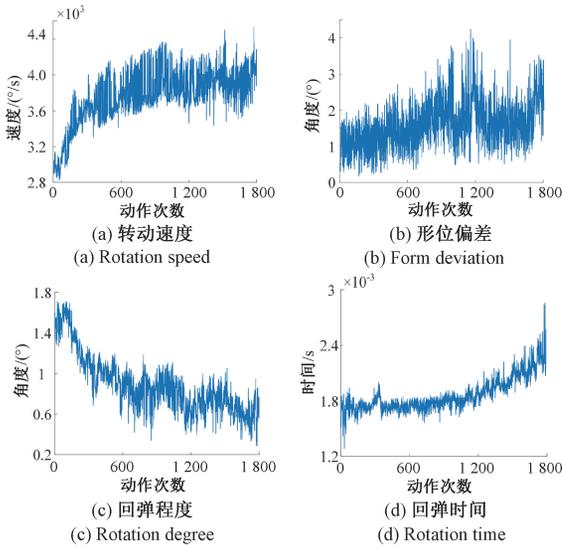


图5 方轴运动特性变化

Fig. 5 Change of square-axis motion characteristic

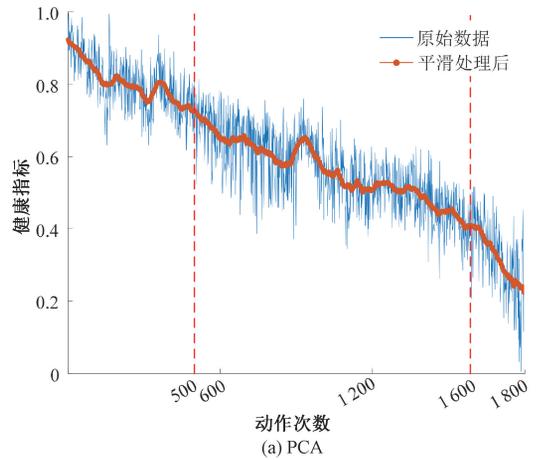
作次数的增加,方轴的形变及运动偏差会加剧,导致方轴转动阶段的转动速度变快,形位偏差变大,而方轴回弹阶段的回弹程度变小,回弹时间变长。故4个特性参数均有趋势性的变化,能够在一定程度上反映储能机构的空运动特性。

### 3.2 运动特性健康指标构建

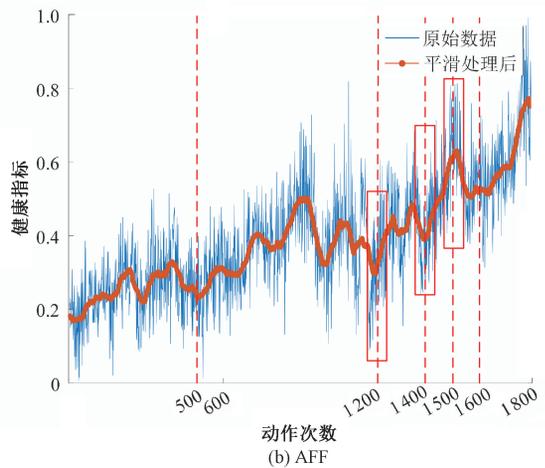
在评估断路器储能机构健康状态时,单一的特征往往无法反映其退化过程,而不同特征间的数值存在差异,且对断路器运行状态的反映效果差别较大。故需要融合4个运动特性参数构建运动特性健康指标,从而更全面地反映储能机构的运行状态和退化过程。

首先将特性参数归一化到相同的尺度,然后分别用主成分分析(principal components analysis, PCA)、AFF和AFF-AAKR 3种方法对特性参数融合,在AFF-AAKR构造健康空间向量时选取  $h = 300$ , 构建的健康指标如图6所示。

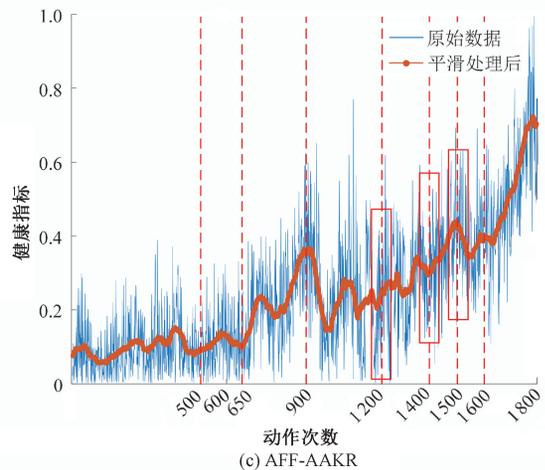
图6展示了不同方法融合的断路器储能机构全寿命周期的健康指数变化。结合图5可以看出,PCA方法构建的指标在500~1600次这一区间趋势单一,对特性参数的局部细节刻画较差,不能详细的反映断路器健康状



(a) PCA



(b) AFF



(c) AFF-AAKR

图6 不同方法构建的健康指标变化

Fig. 6 Changes in health indicator constructed by different methods

态变化。AFF方法构建的指标敏感的捕捉了500~1600次区间特性参数的局部退化信息,但易受退化异常数据影响,在1200、1400和1500次附近区间受到的干扰较大。而通过AFF-AAKR方法融合后的指标有更高性能的优势,不仅包含了500~1600次区间特性参数更多的局部敏感信息,还降低了1200、1400和1500次附近

区间异常数据的干扰,能够更好的反映储能机构退化过程。

因此,本文利用 AFF-AAKR 方法构建的健康指标分析断路器的机械特性退化过程。由健康指标曲线可知,动作次数在 0~650 次这一区间段内的指标较为平稳,可认为方轴没有产生形变和运动偏差,该阶段的性能未发生退化,此时储能机构处于正常运行状态。在动作次数达到 650~900 次时,健康指标逐渐增大,可认为方轴开始产生轻微的形变和运动偏差,该阶段的性能开始退化,此时储能机构处于轻度退化状态。在动作次数达到 900 次之后,健康指数发生突变减小并以较为稳定的速率增大,可认为方轴产生严重的形变和运动偏差,性能严重劣化直至到达其寿命终点,此时储能机构进入严重退化状态。

因此,基于方轴位移信号选取的运动特性参数可以表征储能机构的空间运动特性。经过 AFF-AAKR 方法融合的运动特性健康指标,能够可靠反映断路器储能机构的健康状态。

## 4 振动信号多域特征提取与筛选

### 4.1 储能机构三维振动信号特征提取

储能机构振动信号时间序列是各部件间顺序咬合、传动、摩擦和碰撞运动的体现。鉴于方轴机构的重要性,因此基于方轴位移信号划分振动事件,如图 7 所示,不同区间内储能振动信号持续的时间和强度存在差异,因此按照事件动作时序选取重要振动片段描述信号局部细节,并针对性的分析关键振动事件特征有助于提高储能机构健康状态识别准确率。

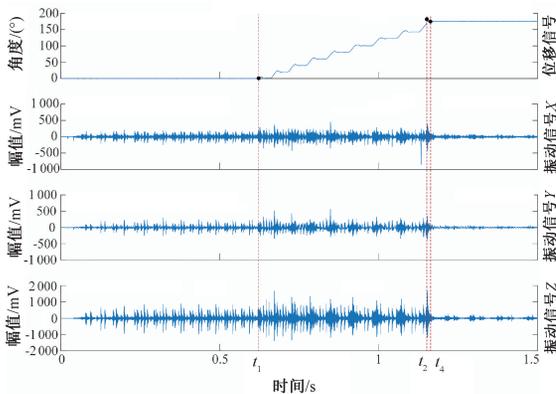


图 7 基于方轴位移的振动信号分段图

Fig. 7 Segmentation map of vibration signals based on square-axis displacement

选取  $t_1 \sim t_4$  时间段作为储能动作关键阶段,结合图 8 三维振动信号时频图分析,可以发现振动信号的频谱主要集中在 0~60 kHz,其中在 0~20 kHz 范围内较为集中,

在 20~60 kHz 范围内较为稀疏。在方轴运动期间,振动信号在 Y 方向的强度最低,X 方向的强度较高,Z 方向的强度最高。因此,可以通过三维振动信号的时域和频域特征参数反映机构的空间运动特点。

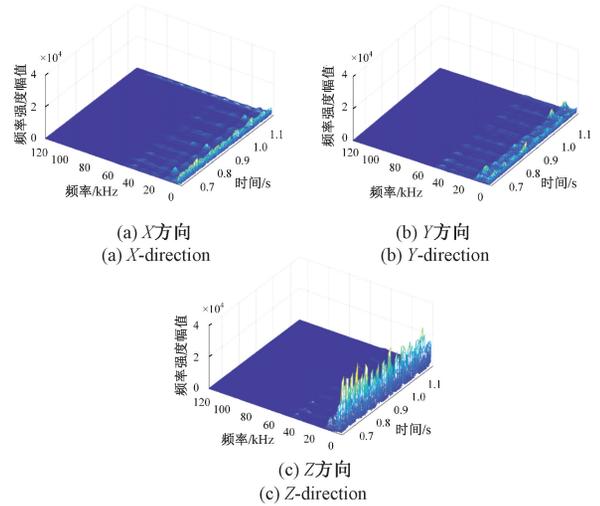


图 8 三维振动信号时频图

Fig. 8 Time-frequency diagrams of 3D vibration signals

鉴于储能机构振动信号的高复杂性和频率分布特点,在多次实验的基础上选择 Daubechies 小波系列的 db4 小波基对关键阶段的三维振动信号进行 4 层小波包分解,获得 16 个重构信号,选取低频段 8 个重构信号的能量熵作为时频域的特征参数。三维振动信号的特征参数分别用  $F_X$ 、 $F_Y$ 、 $F_Z$  表示,以 X 方向振动信号为例,其中  $F_{X1} - F_{X9}$  分别表示时域特征参数均值、有效值、标准差、峰峰值、偏度、峰值指标、波形指标、裕度指标和脉冲指标; $F_{X10} - F_{X18}$  分别表示频域特征参数频谱均值、频谱有效值、频谱标准差、频谱偏度、频率重心、频率有效值、频率标准差、频率偏度和频谱变异系数, $F_{X19} - F_{X26}$  分别表示时频域特征参数,即小波包分解后低频段 8 个重构信号的能量熵。

### 4.2 关键退化特征筛选

振动信号各特征的有效信息存在冗余且重要性不同,为减轻多维数据带来的计算负担及过拟合风险,需要筛选出表征储能机构空间运动特性能力强的关键退化特征。考虑到斯皮尔曼秩相关系数法对数据间相关性的评价有显著的包容性,为充分保留特征中的退化信息,利用斯皮尔曼秩相关系数分别分析三维振动特征和储能机构动作次数的相关性,初步筛选出有较强退化表征能力的特征,如图 9 所示。

可以看出,Z 方向特征与动作次数间的相关性最强,X 方向特征与动作次数间的相关性较强,Y 方向特征与动作次数间的相关性较弱,不同振动方向的特征对退化

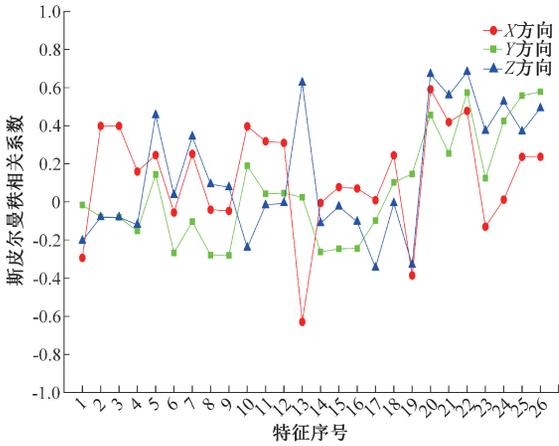


图9 振动信号特征与动作次数的相关性

Fig. 9 Correlation of vibration signal characteristics with the number of actions

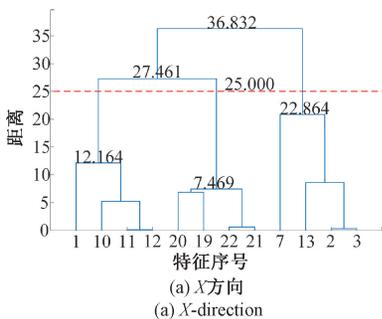
的特征能力不同,故有必要结合三维振动特征对储能机构进行健康状态识别。获得各方向特征的相关系数后,将特征按照相关性系数的绝对值进行排序,每个维度保留绝对值最大的12个特征,作为经过初步特征筛选后的敏感特征集,如表5所示。

表5 三维振动信号敏感特征集

Table 5 3-D vibration signal sensitive feature set

振动信号	敏感特征集
X 方向	$\{F_{X13}, F_{X20}, F_{X22}, F_{X21}, F_{X2}, F_{X3}, F_{X10}, F_{X19}, F_{X11}, F_{X12}, F_{X1}, F_{X7}\}$
Y 方向	$\{F_{Y26}, F_{Y22}, F_{Y25}, F_{Y20}, F_{Y24}, F_{Y19}, F_{Y18}, F_{Y16}, F_{Y14}, F_{Y21}, F_{Y15}, F_{Y16}\}$
Z 方向	$\{F_{Z22}, F_{Z20}, F_{Z13}, F_{Z21}, F_{Z24}, F_{Z26}, F_{Z5}, F_{Z23}, F_{Z25}, F_{Z17}, F_{Z7}, F_{Z19}\}$

得到振动信号的敏感退化特征后,对每个方向的特征进行层次聚类,采用层次聚类方法得到的树状图如图10所示,横轴为特征编号,纵轴表示簇间距离,距离近的特征相似性较强,而距离远的特征相似性较弱。



(a) X-direction

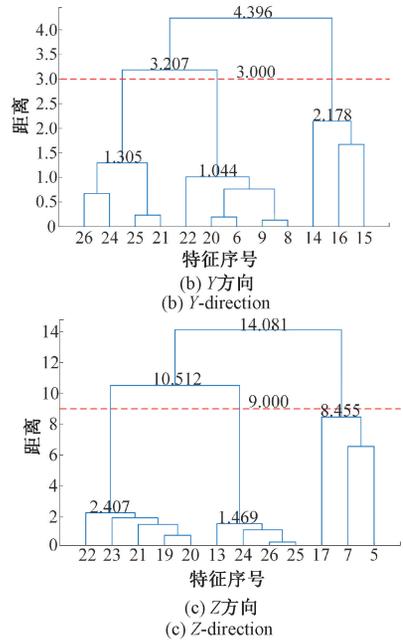


图10 振动信号特征层次聚类树状图

Fig. 10 Hierarchical clustering dendrogram of vibration signal features

在树状图中,与虚线相交的竖线向下延伸的子树的所有叶子节点视为具有较大相似度的特征集,即为一个簇。随着簇间距离的增加,簇的个数在逐渐减少,每个簇中包含的信息逐渐变多;此外,随着簇的不断凝聚,每次凝聚时的簇间距离也在逐渐增大,意味着凝聚需要一个较大的代价<sup>[23]</sup>。故为了以较小的凝聚代价去除冗余保留差异信息,需将各方向的敏感特征较为均匀的凝聚在各簇。

由图10可知,各方向的敏感特征划为3个簇可将其较为均匀的凝聚在各簇,故X方向层次聚类的阈值范围为22.864~27.461,Y方向层次聚类的阈值范围为2.178~3.207,Z方向层次聚类的阈值范围为8.455~10.512,因此阈值分别设置为25.000,3.000和9.000。经过Z-score标准化后,每簇振动特征与基于位移分析的4个运动特性 $Z_1 \sim Z_4$ 的平均互信息由式(15)、(16)计算,根据式(17)选择每个集中对运动特性表征最大的特征组成关键特征集,结果如表6所示。

3个方向筛选的关键退化特征分别为 $\{F_{X12}, F_{X19}, F_{X3}\}$ 、 $\{F_{Y26}, F_{Y22}, F_{Y15}\}$ 、 $\{F_{Z19}, F_{Z13}, F_{Z5}\}$ ,可以看出Y方向的关键特征集涉及频域和时频域,X方向和Z方向的关键特征集涉及时域、频域和时频域,各方向关键特征集具有较好的兼容性,意味着该方法可以在保留大部分退化信息的情况下有效地消除冗余。

表 6 三维振动信号关键特征集

Table 6 3-D vibration signal key feature set

振动信号	聚类结果	关键特征集
X 方向	$C_1 \{F_{X1}, F_{X10}, F_{X11}, F_{X12}\}$	$\{F_{X12},$
	$C_2 \{F_{X20}, F_{X19}, F_{X22}, F_{X21}\}$	$F_{X19},$
	$C_3 \{F_{X7}, F_{X13}, F_{X2}, F_{X3}\}$	$F_{X3}\}$
Y 方向	$C_1 \{F_{Y26}, F_{Y24}, F_{Y25}, F_{Y21}\}$	$\{F_{Y26},$
	$C_2 \{F_{Y22}, F_{Y20}, F_{Y6}, F_{Y9}, F_{Y8}\}$	$F_{Y22},$
	$C_3 \{F_{Y14}, F_{Y16}, F_{Y15}\}$	$F_{Y15}\}$
Z 方向	$C_1 \{F_{Z22}, F_{Z23}, F_{Z21}, F_{Z19}, F_{Z20}\}$	$\{F_{Z19},$
	$C_2 \{F_{Z13}, F_{Z24}, F_{Z26}, F_{Z25}\}$	$F_{Z13},$
	$C_3 \{F_{Z17}, F_{Z7}, F_{Z5}\}$	$F_{Z5}\}$

### 5 基于 1D-CNN 的性能退化识别

在获得三维振动信号的 9 个关键退化特征基础上,结合平滑处理后的运动特性健康指标构建时间序列样本。将退化特征矢量作为输入,平滑处理后的运动特性健康指标作为输出,通过深度学习中的 1D-CNN、循环神经网络(recurrent neural network, RNN)和多层感知器(multi-layer perception, MLP)3 种模型进行回归分析。本文中的模型训练和测试通过 PyCharm 软件下的 PyTorch 框架实现,Python 版本为 3.7,计算机 CPU 为 9400F, GPU 为 NVIDIA RTX3060。

其中 1D-CNN 的卷积层个数为 2,每层的卷积核个数为 64,卷积层和池化层的卷积核尺寸均为 2,卷积层核步长为 1,池化层核步长为 2,结构参数设置如表 7 所示;RNN 和 MLP 的隐含层个数为 2,每层的神经元个数为 64。3 种模型的初始学习率设置为 0.001,激活函数使用 Relu 函数,迭代次数为 200。均采用相同的训练集和测试集,数据的前 80% 作为训练集,后 20% 作为测试集。不同模型的测试结果如图 11 所示,测试评价指标拟合优度  $R^2$ 、均方根误差 RMSE 和平均绝对误差 MAE 详见表 8。

表 7 1D-CNN 结构参数设置

Table 7 1D-CNN structural parameterization

网络层	核尺寸	步长	核数量	输出维度
输入层	-	-	-	9×1
卷积层 1	2×1	1	64	8×1×64
池化层 1	2×1	2	-	4×1×64
卷积层 2	2×1	1	64	3×1×64
池化层 2	2×1	2	-	1×1×64
全连接层	-	-	-	1×1

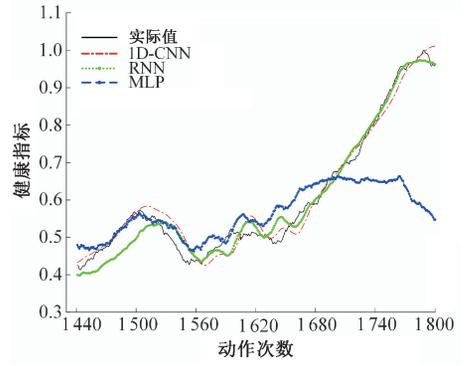


图 11 不同模型的测试结果对比

Fig. 11 Test results comparison of different models

由图 11 可以看出,相较于其他方法 1D-CNN 识别出的健康指标与实际的值的拟合度最好。

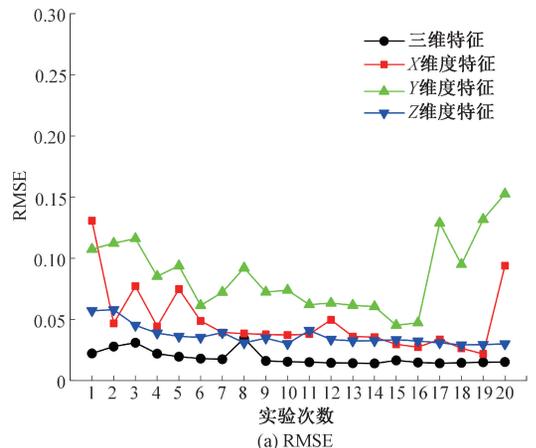
表 8 3 种模型的测试结果

Table 8 Test results of the three models

模型	$R^2$	RMSE	MAE
1D-CNN	0.969 8	0.030 6	0.023 3
RNN	0.925 3	0.048 0	0.029 9
MLP	0.484 0	0.126 2	0.074 7

由表 8 所示,1D-CNN 的  $R^2$  为 0.969 8, RMSE 为 0.030 6, MAE 为 0.023 3,均优于另 2 个模型的评价指标,故 1D-CNN 对多状态参数进行回归分析有很好的效果。

为了验证采用三维振动信号关键退化特征作为 1D-CNN 模型输入的优越性,分别将三维振动关键退化特征与一维特征作为输入的结果进行比较。为了避免实验的偶然性,对同一实验重复 20 次,然后计算各测试结果的 RMSE 和 MAE,如图 12 所示。20 次实验不同输入的平均 RMSE 和平均 MAE 如表 9 所示。



(a) RMSE

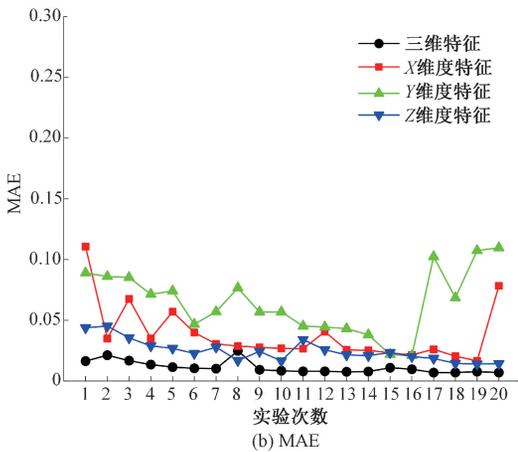


图 12 不同输入测试误差对比

Fig. 12 Test errors comparison of different inputs

表 9 1D-CNN 不同输入的平均误差

Table 9 1D-CNN average errors for different inputs

模型输入	平均 RMSE	平均 MAE
三维特征	0.018 6	0.011 2
X 维度特征	0.048 3	0.038 2
Y 维度特征	0.086 7	0.065 1
Z 维度特征	0.036 5	0.024 8

三维特征小于 X、Y、Z 单一维度特征的测试误差,平均 RMSE 相较于 X、Y、Z 维度特征分别减少了 61.49%、78.55%、49.04%;平均 MAE 分别减少了 70.68%、82.80%、54.84%。表明三维振动信号对储能机构的空间运动特性表征效果优于单一维度振动信号,能够更好的反映储能机构性能退化程度,进行健康状态识别。

## 6 结 论

本文提出了基于空间运动特性的断路器健康状态识别方法,并根据实验数据进行了有效性验证,得出了以下结论。

空间运动特性差异可直接反映机械性能的退化,基于位移信号获取的方轴转动速度、形位偏差、回弹程度和回弹时间 4 个运动特性,能够在宏观上体现退化的趋势性。通过 AFF-AAKR 模型构建的运动特性健康指标,在包含更多局部敏感信息的同时降低了异常数据的干扰,从空间运动角度准确地反映了储能机构性能退化过程。

不同维度的多域振动特征有显著差异,多重特征筛选方法得到了能够表征空间运动特性的关键退化特征,可以在保留大部分退化信息的情况下有效地消除冗余。基于 1D-CNN 模型进行健康状态识别表明三维振动信号

较单一维度振动信号对储能机构的空间运动特性表征效果更好, RMSE 为 0.018 6, MAE 为 0.011 2, 可更精准地识别断路器的健康状态。

本文基于三维振动信号对空间运动特性进行表征,识别了断路器的健康状态,但尚存在不足之处。后续研究应考虑断路器实际运行工况下,各种材料的机械变形和锈蚀对性能退化的影响,此外应获取更多的试验数据,对运动特性健康指标和回归模型的优化进行深入研究,以实现实际运行工况下的断路器健康状态可在线识别。

## 参考文献

- [1] 盛戈峰, 钱勇, 罗林根, 等. 面向新型电力系统的电力设备运行维护关键技术及其应用展望[J]. 高电压技术, 2021, 47(9): 3072-3084.  
SHENG G H, QIAN Y, LUO L G, et al. Technologies and application prospects for operation and maintenance of power equipment in new type power system[J]. High Voltage Engineering, 2021, 47(9): 3072-3084.
- [2] 孙曙光, 唐尧, 王景芹, 等. 基于多信号特征融合的断路器操作机构寿命预测[J]. 高电压技术, 2022, 48(11): 4455-4468.  
SUN SH G, TANG Y, WANG J Q, et al. Life prediction of operating mechanism for circuit breaker based on multiple signal feature fusion [J]. High Voltage Engineering, 2022, 48(11): 4455-4468.
- [3] 赵书涛, 许文杰, 李云鹏, 等. 基于优选泛特征的真空断路器弹簧机构储能状态辨识方法[J]. 高电压技术, 2021, 47(11): 3777-3784.  
ZHAO SH T, XU W J, LI Y P, et al. Identification method for energy storage state of spring mechanism of vacuum circuit breaker based on optimal multi-characteristics [J]. High Voltage Engineering, 2021, 47(11): 3777-3784.
- [4] 赵书涛, 许文杰, 刘会兰, 等. 基于振动信号谱形状熵特征的高压断路器操动状态辨识方法[J]. 电工技术学报, 2022, 37(9): 2170-2178.  
ZHAO SH T, XU W J, LIU H L, et al. Identification method for operation state of high voltage circuit breakers based on spectral shape entropy characteristics of vibration signals [J]. Transactions of China Electrotechnical Society, 2022, 37(9): 2170-2178.
- [5] 孙曙光, 张婷婷, 王景芹, 等. 基于连续小波变换和 MTL-SEResNet 的断路器故障程度评估[J]. 仪器仪表学报, 2022, 43(6): 162-173.  
SUN SH G, ZHANG T T, WANG J Q, et al. Fault degree evaluation of circuit breaker based on continuous wavelet transform and MTL-SEResNet [J]. Chinese Journal of Scientific Instrument, 2022, 43(6):

- 162-173.
- [ 6 ] 孙曙光, 王泽伟, 陈静, 等. 基于卷积变分自编码和多头自注意力机制的断路器剩余机械寿命预测[J]. 仪器仪表学报, 2024, 45(3): 106-118.  
SUN SH G, WANG Z W, CHEN J, et al. Remaining mechanical useful life prediction for circuit breaker based on convolutional variational autoencoder and multi-head self-attention[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 106-118.
- [ 7 ] 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 a novel feature fusion metric learning[J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 98-105.
- [ 8 ] 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.
- [ 9 ] 丁巧林, 何梦媛, 王亚潇, 等. 断路器操作三维振动信号差异特征的研究[J]. 高压电器, 2019, 55(4): 46-51.  
DING Q L, HE M Y, WANG Y X, et al. Difference of three-dimensional signals on breaker operation[J]. High Voltage Apparatus, 2019, 55(4): 46-51.
- [ 10 ] PANIGRAHY P S, CHATTOPADHYAY P. Tri-axial vibration based collective feature analysis for decent fault classification of VFD fed induction motor [ J ]. Measurement, 2021, 168: 108460.
- [ 11 ] ZHOU F, XU P CH, BAI X ZH, et al. Optimal layout method of multiple vibration sensors based on motor vibration frequency response [ J ]. Journal of Vibration Engineering & Technologies, 2023, 11(2): 683-697.
- [ 12 ] 李德阁, 武建文, 马速良, 等. 基于行程信息的断路器弹簧故障程度诊断[J]. 高压电器, 2018, 54(4): 20-27.  
LI D G, WU J W, MA S L, et al. Fault degree diagnosis of circuit breaker spring based on travel signal[J]. High Voltage Apparatus, 2018, 54(4): 20-27.
- [ 13 ] 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.
- [ 14 ] 周学, 李东晖, 金玥, 等. 考虑空间形位偏差的万能式断路器关键零件断裂失效研究[J]. 电工技术学报, 2022, 37(6): 1595-1605.  
ZHOU X, LI D H, JIN Y, et al. Fracture failure process of key part of air circuit breaker considering spatial shape and position deviation [ J ]. Transactions of China Electrotechnical Society, 2022, 37(6): 1595-1605.
- [ 15 ] 杜太行, 崔景瑞, 孙曙光, 等. 基于混合式仿真模型的交流接触器动态特性研究[J]. 电子测量与仪器学报, 2019, 33(10): 187-194.  
DU T H, CUI J R, SUN SH G, et al. Study on dynamic characteristics of AC contactor based on hybrid simulation model [ J ]. Journal of Electronic Measurement and Instrumentation, 2019, 33(10): 187-194.
- [ 16 ] 刘韵婷, 刘鑫, 高宇. 基于FAMGAN的轮胎X光图像缺陷检测[J]. 电子测量与仪器学报, 2023, 37(12): 58-66.  
LIU Y T, LIU X, GAO Y. Defect detection of tire X-ray images based on FAMGAN [ J ]. Journal of Electronic Measurement and Instrumentation, 2023, 37(12): 58-66.
- [ 17 ] CHEN C, XU T H, WANG G, et al. Railway turnout system RUL prediction based on feature fusion and genetic programming [ J ]. Measurement, 2020, 151: 107162.
- [ 18 ] BARALDI P, BONFANTI G, ZIO E. Differential evolution-based multi-objective optimization for the definition of a health indicator for fault diagnostics and prognostics [ J ]. Mechanical Systems and Signal Processing, 2018, 102(2): 382-400.
- [ 19 ] 吴启航, 丁晓喜, 何清波, 等. 齿轮箱故障边缘智能诊断方法及应用研究[J]. 仪器仪表学报, 2024, 45(1): 70-80.  
WU Q H, DING X X, HE Q B, et al. Edge intelligent fault diagnosis method in the application of gearbox[J]. Chinese Journal of Scientific Instrument, 2024, 45(1): 70-80.
- [ 20 ] 尹诗, 侯国莲, 胡晓东, 等. 风力发电机组发电机前轴承故障预警及辨识[J]. 仪器仪表学报, 2020, 41(5): 242-251.  
YIN SH, HOU G L, HU X D, et al. Fault warning and identification of front bearing of wind turbine generator[J]. Chinese Journal of Scientific Instrument, 2020, 41(5): 242-251.
- [ 21 ] 潘超, 陈祥, 蔡国伟, 等. 基于小波包尺度-能量占比

- 的变压器三相不平衡绕组振动特征辨识[J]. 仪器仪表学报, 2020, 41(4): 129-137.
- PAN CH, CHEN X, CAI G W, et al. Identification of winding vibration characteristics of three-phase unbalanced transformer based on scale-energy ratio of wavelet packet[J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 129-137.
- [22] 刘树鑫, 周柱, 刘洋, 等. 基于振动信号的交流接触器触头系统退化阶段划分[J]. 高电压技术, 2023, 49(12): 4971-4981.
- LIU SH X, ZHOU ZH, LIU Y, et al. Degradation phase division of ac contactor contact system based on vibration signal[J]. High Voltage Engineering, 2023, 49(12): 4971-4981.
- [23] 李冠争, 李斌, 王帅, 等. 基于特征选择和随机森林的电力系统受扰后动态频率预测[J]. 电网技术, 2021, 45(7): 2492-2502.
- LI G ZH, LI B, WANG SH, et al. Dynamic frequency prediction of power system post-disturbance based on feature selection and random forest[J]. Power System Technology, 2021, 45(7): 2492-2502.
- [24] 孟圣洁, 于万钧, 陈颖. 最大相关和最大差异的高维数据特征选择算法[J]. 计算机应用, 2024, 44(3): 767-771.
- MENG SH J, YU W J, CHEN Y. Feature selection algorithm for high-dimensional data with maximum correlation and maximum difference [J]. Journal of Computer Applications, 2024, 44(3): 767-771.
- [25] 车畅畅, 王华伟, 倪晓梅, 等. 基于 1D-CNN 和 Bi-LSTM 的航空发动机剩余寿命预测[J]. 机械工程学报, 2021, 57(14): 304-312.
- CHE CH CH, WANG H W, NI X M, et al. Residual life prediction of aeroengine based on 1D-CNN and Bi-LSTM[J]. Journal of Mechanical Engineering, 2021, 57(14): 304-312.
- [26] 周静雷, 贺家琛, 崔琳. CNN-GRU 和 SSA-VMD 在扬声器异常声分类中的应用[J]. 电子测量与仪器学报, 2023, 37(3): 161-168.
- ZHOU J L, HE J CH, CUI L. Application of CNN-GRU and SSA-VMD in loudspeaker abnormal sound classification[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 161-168.
- [27] 赵世昊, 周建华, 伏云发. 注意力机制 CNN 结合肌电特征矩阵的手势识别研究[J]. 电子测量与仪器学报, 2023, 37(6): 59-67.
- ZHAO SH H, ZHOU J H, FU Y F. Investigation of gesture recognition using attention mechanism CNN combined electromyography feature matrix[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(6): 59-67.

### 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. degree, M. Sc. degree and Ph. D. degree 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.



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. degree, M. Sc. degree and Ph. D. degree 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.