

DOI: 10.19783/j.cnki.pspc.230960

基于 SO-PAA-GAF 和 AdaBoost 集成学习的高压断路器故障诊断

司江宽¹, 吐松江·卡日¹, 范想², 高文胜³, 朱炜¹

(1. 新疆大学电气工程学院, 新疆 乌鲁木齐 830047; 2. 国网新疆电力公司哈密供电公司, 新疆 哈密 839000;
3. 清华大学电机工程与应用电子技术系电力系统及发电设备控制和仿真国家重点实验室, 北京 100084)

摘要: 针对在小样本和复杂工况下高压断路器故障诊断识别精度不高的问题, 提出一种基于振动信号处理和 AdaBoost 集成学习的高压断路器故障诊断方法。首先, 搭建高压断路器实验平台并采集 8 种工况下的分闸振动信号。其次, 对振动信号进行绝对值处理后, 使用分段聚合近似(piecewise aggregate approximation, PAA)进行分段平均, 将输出的新序列采用格拉姆角场(Gramian angular field, GAF)转换成图片, 并使用 Relief F 方法对提取的高维图片特征进行重要度排序。最后, 将保留的重要特征输入到 AdaBoost 集成学习模型进行故障诊断, 并用蛇优化算法确定最优 PAA 分段步长和输入分类器特征数量, 以进一步提高故障诊断精度。通过分析多种信号处理方式及分类模型可知, 图片信号和 AdaBoost 集成学习模型能够有效处理振动信号并准确判断故障类型, 为准确、可靠地诊断高压断路器故障提供了新途径。

关键词: 高压断路器; 振动信号处理; 分段聚合近似; 格拉姆角场; 故障诊断

Fault diagnosis of high-voltage circuit breaker based on SO-PAA-GAF and AdaBoost ensemble learning

SI Jiangkuan¹, TUSONGJIANG·Kari¹, FAN Xiang², GAO Wensheng³, ZHU Wei¹

(1. School of Electrical Engineering, Xinjiang University, Urumqi 830047, China; 2. Hami Power Supply Company, Xinjiang Electrical Power Corporation of SGCC, Hami 839000, China; 3. State Key Laboratory of Control and Simulation of Power Systems and Generation Equipment, Department of Electrical Engineering, Tsinghua University, Beijing 100084, China)

Abstract: Aiming at the low accuracy of high-voltage circuit breaker fault diagnosis under small samples and complex working conditions, a fault diagnosis method of high-voltage circuit breaker based on vibration signal processing and AdaBoost ensemble learning is proposed. First, the high-voltage circuit breaker test platform is built and the switching vibration signals are collected under 8 working conditions. Second, after absolute value processing of vibration signals, piecewise aggregate approximation (PAA) is used to do piecewise averaging, and Gramian angular field (GAF) is used to convert new output sequences into pictures. The Relief F method is used to sort the importance of the extracted high-dimensional image features. Finally, the retained important features are input into the AdaBoost ensemble learning model for fault diagnosis, and the snake optimization algorithm is used to determine the optimal PAA step size and the number of input classifier features to further improve the fault diagnosis accuracy. The comparison and analysis results with various signal processing methods and classification models indicate that picture signal and AdaBoost ensemble learning model can deal with vibration signal effectively and judge fault type accurately, which provides a new way to diagnose high-voltage circuit breaker fault accurately and reliably.

This work is supported by the National Natural Science Foundation of China (No. 52067021).

Key words: high-voltage circuit breaker; vibration signal processing; piecewise aggregate approximation; Gramian angular field; fault diagnosis

基金项目: 国家自然科学基金项目资助(52067021); 新疆维吾尔自治区自然科学基金项目资助(2022D01C35); 新疆维吾尔自治区优秀青年科技人才培养项目资助(2019Q012)

0 引言

高压断路器是电力系统重要的控制与保护设备, 具有价格昂贵、投运数量多、运维检修量大及要求高等特点。据统计, 变电站维护费用的一半以上用在高压断路器上, 而断路器日常运维与各类检修成本占其费用的 60%^[1]。断路器发生缺陷或故障时, 不仅导致设备损坏、非计划停电及经济损失, 甚至出现人员意外伤亡。因此, 如何针对性发现高压断路器的缺陷和故障, 成为目前电力系统亟需解决的难题。

高压断路器在动作过程中会产生剧烈振动。而振动信号包含丰富的断路器动作信息, 如何有效提取和准确处理振动信号特征是日前断路器故障诊断的主要难题。由于断路器振动信号具有非平稳特点, 因此快速傅里叶变换等方法无法得到有效应用。目前主要采用的方法是对一维振动信号进行频率分解, 如短时傅里叶变换、经验模态分解^[2-4]和小波变换^[5-7]等。但是以上方法都存在其不足, 如短时傅里叶变换需要确定合适宽度的时间窗口, 经验模态分解存在模态混叠和端点效应的现象, 小波变换容易受到邻近谐波的影响。近些年, 一维信号转换为二维图片的方法得到快速应用, 图片信号处理方法主要有深度学习和传统机器学习。其中采用深度学习的方法将电流信号转化为灰度图片, 并使用深度残差网络完成了分类; 文献[9-10]将振动信号转换为时频图, 利用卷积神经网络进行故障诊断, 取得良好效果。但上述深度学习算法在数据样本数量较少时容易出现过拟合现象。文献[11-12]分别通过小波变换、小波包变换把一维信号转换为时频图, 通过挖掘图片特征并结合传统机器学习模型实现断路器故障诊断; 但时频图只能展示出信号总体效果, 而不能描述信号瞬时特征。

为了精准提取和处理信号瞬时特征, 本文提出一种基于 PAA-GAF 信号处理方法, 该方法可以将振动信号转换成能保留瞬时信息的灰度图片。通过提取图片纹理等特征^[13]并使用 Relief F 方法进行特征重要度排序, 然后使用集成 K 最邻近(k-nearest neighbor, KNN)、朴素贝叶斯(naive bayes, NB)、逻辑回归(logistic regression, LR)和支持向量机(support vector machine, SVM)4 种分类器的 AdaBoost 集成分类模型对高压断路器进行故障诊断; 最后, 采用蛇优化算法探究最优 PAA 分段步长和最佳输入分类器特征数量, 进一步提高故障诊断精度。实验结果表明, 本文方法不仅克服了上述一维信号频率分

解方法的缺陷, 解决了二维图信号结合深度学习受样本数量影响的问题, 而且可精确提取振动信号的瞬时特征并准确判断故障类型。

1 PAA-GAF 信号处理

1.1 分段聚合近似

PAA^[14]是一种通过对时间序列分段平均, 实现减少计算复杂度、提高信号质量的方法, 其计算步骤如下所述。

设长度为 n 的振动信号序列 $Q = \{Q_1, Q_2, \dots, Q_c, \dots, Q_n\} (c=1, \dots, n)$ 能用另一种长度为 m 的序列 $C = \{C_1, C_2, \dots, C_l, \dots, C_m\} (l=1, \dots, m)$ 表示, 其中 $n > m$ 。令 $m = n/k$, 其中: k 为分段步长; m 可为向负无穷方向取的整数。最后一段若小于 k , 则整合到上一段, C_l 满足式(1)。

$$C_l = \frac{1}{k} \sum_{c=k(l-1)+1}^{k \times l} Q_c, 1 \leq l \leq m \quad (1)$$

断路器振动信号具有随机性和高噪声的特点, 会干扰特征提取和选择, 影响模型诊断性能。而 PAA 技术将振动信号分段平均, 分段平均后的信号不仅可以大致描述原始信号的基本情况和变化趋势, 而且随着分段步长的增加, 每段数据的随机性和噪声减弱, 提高了信号质量和可靠性, 从而有效提高了诊断精度。但如果分段步长太大也会造成信号关键信息缺失, 影响分类准确性。

1.2 格拉姆角场

GAF^[15]是将一维信号转换成图片的方法。与时频图展示信号总体效果不同, GAF生成的图片能够描述信号瞬时特征。

信号分段平均后得到长度为 m 的序列 $C = \{C_1, C_2, \dots, C_l, \dots, C_m\} (l=1, \dots, m)$, 然后将 C_l 压缩到 $[1, -1]$, 表示为 \tilde{C}_l , 接着将 \tilde{C}_l 的值映射为角度 λ_M , 将时间映射为半径 r , 如式(2)所示。

$$\begin{cases} \lambda_M = \arccos(\tilde{C}_l), -1 \leq \tilde{C}_l \leq 1, \tilde{C}_l \in \tilde{C} \\ r = \frac{t_l}{B}, t_l \in B \end{cases} \quad (2)$$

式中: \tilde{C} 为压缩后序列的集合; t_l 为对应的时间; B 为极坐标跨度的系数。

用三角函数变换得到 $m \times m$ 的格拉姆矩阵 G_{AF} 。

$$G_{AF} = \cos(\lambda_M + \lambda_N) \quad (3)$$

式中: $\lambda_N \in \lambda, N=1, \dots, m$, 且 M 可以与 N 相等。

数据序列通过 GAF 变换能生成唯一的极坐标映射图, 通过半径 r 保持序列对时间的联系。生成的图片如图 1 所示, 图片从左上角到右下角对应递

增的时间序列。

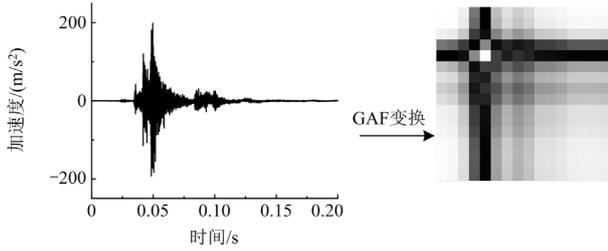


图1 振动信号的GAF变换

Fig. 1 GAF transformation of vibration signal

高压断路器内部结构前后次序的碰撞在振动信号波形上体现为时序先后、振幅不同的冲击。撞击力度越大、固定的螺丝越松动，振动幅度就越大，信号波形上冲击幅值就越高。由于断路器内部元件的动作状态可以在振动波形上以该时刻冲击幅值的变化表现出来，因此波形在不同时间上的幅值信息为断路器振动信号重要特征。

由于振动信号时间序列具有维度高、波形随机(即使同一状态下断路器前后两次动作的波形也不完全一致)以及高噪声的特性，因此直接对原始序列进行分析势必会造成处理时间长、结果不准确以及研究结论可信度低等。为了改善上述情况，提取反映整体分布的重要特征(幅值)信息，减少冗余噪声的干扰。本文首先对振动波形进行了绝对值处理，然后用PAA方法对绝对值处理后的波形分段平均，最后对由每段平均幅值组成的新序列进行GAF变换，如图2所示。

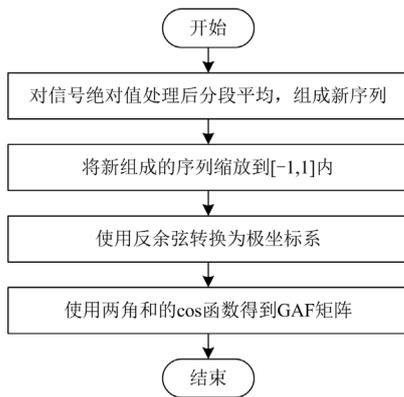


图2 PAA-GAF转换图片流程图

Fig. 2 Flow chart for picture transformation by PAA-GAF

2 图片特征提取与选择

2.1 基于GGCM纹理特征提取

文献[16]提出了一种灰度-梯度共生矩阵方法(gray-gradient co-occurrence matrix, GGCM),用于反

应图像在灰度和梯度两个方面的基本特性。设元素 $H(i, j)$ 是在归一化的灰度图像和梯度图像中共同具有灰度为 i 、梯度为 j 的像素点总数。如 $H(1,2)=3$,说明图像点灰度为1、梯度为2的像素点总数共有3个。图像总点数归一化后得到的概率定义为 $P(i, j)$,纹理特征如表1所示。

GGCM集中反映了图像中灰度和梯度两种最基本要素的相互关系。各像点的灰度是构成一副图像的基础,而梯度是构成图像边缘轮廓的要素,这两种要素包含了图片的基本纹理信息。

2.2 基于GMRF纹理特征提取

高斯-马尔科夫随机场^[17](Aaussian Markov random field, GMRF)中任一像素点 a 的像素值 $y(a)$ 与周围所有邻域像素有关,可用条件概率表示为

$$P(y(a) | y(a+E), E \in G) \quad (4)$$

式中, G 是以 a 为中心、 E 为半径,但不包括 a 的对称邻域。

设 S 为 $V \times V$ 图像块上的点集, $S = \{\alpha, \beta\}$, $1 \leq \alpha, \beta \leq V$, GMRF的模型如式(5)所示。

$$y(S) = \sum_{r \in G_a} \theta_r [y_1(a+E)] + e(a) \quad (5)$$

式中: G_a 为像素点 a 的GMRF邻域; $y_1(a+E)$ 为 S 中的点; θ_r 为对称邻域像素的权值; $e(a)$ 是均值为0的高斯分布噪声。

将 S 中的每个点代入式(5)得到差分方程,如式(6)所示。

$$y(a) = R_a^T \theta + e(a) \quad (6)$$

式中: R_a^T 为关于 $y(a)$ 的矩阵; θ 为待估计特征向量。最小平方误差准则估计求解可得到:

$$T_u = \left(\sum_{a \in S} R_a R_a^T \right)^{-1} \left(\sum_{a \in S} R_a y(a) \right) \quad (7)$$

式中, $T_u (u=16, \dots, 27)$ 为提取的12个特征。

2.3 Relief F特征选择

Relief F通过比较最近邻同种样本和异种样本的距离来更新特征权重,经过不断迭代计算各个特征平均权重^[18]。权重值越大,表明该特征分类能力越强。

特征个数对分类结果有着重要的影响。特征过少可能导致分类器无法准确判断不同类别之间的差异,而特征过多可能会导致过拟合和复杂度过高,甚至过多的无关特征会干扰分类结果,降低诊断精度,因此选择适当数量的特征可以提高分类器的分类性能和泛化能力。

表 1 灰度-梯度共生矩阵特征
Table 1 Features of gray-gradient co-occurrence matrix

序号	特征名称	计算公式	物理意义
1	灰度平均	$T_1 = \sum_i i \left[\sum_j P(i, j) \right]$	用来表示灰度的平均值
2	梯度平均	$T_2 = \sum_j j \left[\sum_i P(i, j) \right]$	用来表示梯度的平均值
3	灰度标准差	$T_3 = \left\{ \sum_i (i - T_1)^2 \left[\sum_j P(i, j) \right] \right\}^{1/2}$	用来表示灰度的标准差
4	梯度标准差	$T_4 = \left\{ \sum_j (j - T_2)^2 \left[\sum_i P(i, j) \right] \right\}^{1/2}$	用来表示梯度的标准差
5	小梯度优势	$T_5 = \left[\sum_i \sum_j \frac{H(i, j)}{j^2} \right] / \left[\sum_i \sum_j H(i, j) \right]$	用来反映图像的灰度变化剧烈程度, 小梯度像素数多, 小梯度优势大
6	大梯度优势	$T_6 = \left[\sum_i \sum_j j^2 H(i, j) \right] / \left[\sum_i \sum_j H(i, j) \right]$	用来反映图像的灰度变化剧烈程度, 大梯度像素数多, 大梯度优势大
7	灰度分布不均匀	$T_7 = \left\{ \sum_i \left[\sum_j H(i, j) \right]^2 \right\} / \left[\sum_i \sum_j H(i, j) \right]$	用来衡量图像灰度分布的不均匀程度
8	梯度分布不均匀	$T_8 = \left\{ \sum_j \left[\sum_i H(i, j) \right]^2 \right\} / \left[\sum_i \sum_j H(i, j) \right]$	用来衡量图像梯度分布的不均匀程度
9	能量	$T_9 = \sum_i \sum_j [P(i, j)]^2$	用来表示图像的能量分布
10	相关性	$T_{10} = \frac{1}{T_3 T_4} \sum_i \sum_j (i - T_1)(j - T_2)P(i, j)$	用来衡量图像像素间的相似程度
11	灰度熵	$T_{11} = - \left\{ \sum_i \left[\sum_j P(i, j) \right] \log \left[\sum_j P(i, j) \right] \right\}$	用来度量图像灰度的信息量
12	梯度熵	$T_{12} = - \left\{ \sum_j \left[\sum_i P(i, j) \right] \log \left[\sum_i P(i, j) \right] \right\}$	用来度量图像梯度的信息量
13	混合熵	$T_{13} = - \sum_i \sum_j P(i, j) \log P(i, j)$	用来度量图像灰度和梯度的信息量
14	惯性	$T_{14} = \sum_i \sum_j (i - j)^2 P(i, j)$	用来反映图像灰度空间分布的复杂程度, 与图像清晰程度成正比
15	逆差距	$T_{15} = \sum_i \sum_j \frac{1}{1 + (i - j)^2} P(i, j)$	用来检验图像局部的均匀性

为去除无效或冗余特征, 提升模型诊断精度, 本文通过 Relief F 特征选择方法对提取的 27 维特征进行重要度排序并筛选重要特征、建立特征数据库。

3 振动信号特征选择与识别

3.1 AdaBoost 集成分类模型

AdaBoost^[19-20]是一种集成算法, 其算法思想是用不同的权重把多个弱分类器集成起来组成一个强分类器。本文采用一对一法将多分类问题转化为若干个二分类问题, 再训练KNN、NB、LR和SVM^[21]模型作为解决二分类问题的弱分类器, 并用 AdaBoost思想将4种弱分类器集成得到强分类器。

训练样本权值的初始化计算如式(8)所示。

$$D_o(\omega) = 1/W \quad (8)$$

式中: o 为迭代次数; ω 为训练样本; W 为训练样本总数。

第 g 个弱分类器, 其误差 ε_g 、权重 A_g 分别为

$$\begin{cases} \varepsilon_g = \sum_{\omega=1}^W D_g(h_g(\omega)) \quad h_g(\omega) \neq y(\omega) \\ A_g = \frac{1}{2} \ln \left(\frac{1 - \varepsilon_g}{\max(\varepsilon_g, 1 \times 10^{-15})} \right) \end{cases} \quad (9)$$

式中: $h_g(\omega)$ 为预测输出标签; $y(\omega)$ 为实际标签; D_g 为样本权重。

重新计算样本权重 D_g , 如式(10)所示。

$$D_{g+1}(\omega) = \frac{D_g(\omega)}{Z_g} \exp(-A_g y(\omega) h_g(\omega)) \quad (10)$$

式中, Z_g 为样本权重归一化系数。

由此得到强分类器的输出 H_o ，如式(11)所示。

$$H_o = \sum_{g=1}^4 A_g h_g \quad (11)$$

对强分类器进行 o 次迭代，取正确率最高的强分类器作为最优二分类器。利用 n 类样本训练 $[n \times (n-1)]/2$ 个最优二分类器，将每个最优二分类器输入测试集特征向量得到预测标签，最后用投票法输出多分类问题的结果。

3.2 基于蛇优化的参数确定

蛇优化算法是通过模拟蛇的觅食和繁殖行为提出的优化算法^[22]。算法的初始化需要生成均匀分布的随机种群，此后，将种群分为数量相等的雌雄两个部分，接下来蛇的勘探和开发阶段主要受温度 T_{emp} 和食物量 F 的影响，如式(12)表示。

$$\begin{cases} T_{\text{emp}} = \exp(-\tau / \Omega) \\ F = d_1 \times \exp((\tau - \Omega) / \Omega) \end{cases} \quad (12)$$

式中： τ 为当前的迭代次数； Ω 为最大的迭代次数； d_1 取值较大时能够有效提高模型前期的收敛速度，但可能会陷入局部最优，本文取0.5。食物量 F 和温度 T_{emp} 影响蛇交配(新个体取代适应度差个体的过程)，其合适的取值可以增强模型性能。

在 $F < 0.25$ 时，蛇通过选择任何随机位置来搜索食物，并更新其位置，此为勘探阶段，公式为

$$\begin{cases} X_i^m(\tau+1) = X_r^m(\tau) \pm d_2 A_m ((X_{\text{max}} - X_{\text{min}})r + X_{\text{min}}) \\ X_i^f(\tau+1) = X_r^f(\tau) \pm d_2 A_f ((X_{\text{max}} - X_{\text{min}})r + X_{\text{min}}) \\ A_m = \exp(-f_r^m / f_i^m) \\ A_f = \exp(-f_r^f / f_i^f) \end{cases} \quad (13)$$

式中： X_i^m 、 X_i^f 分别为雄性、雌性位置； X_r^m 、 X_r^f 分别为随机选择的雄性、雌性的位置； d_2 取值较小时能够保证种群局部搜索能力，加快收敛速度，本文取0.05； r 是[0, 1]范围内的随机数； A_m 、 A_f 分别为雄性、雌性寻找食物的能力； f_r^m 、 f_r^f 分别为 X_r^m 、 X_r^f 的适应度值； f_i^m 、 f_i^f 分别为 X_i^m 、 X_i^f 的适应度值。

在 $F > 0.25$ 时，蛇处于开发阶段。当 $T_{\text{emp}} > 0.6$ 时，那么蛇只会寻找食物，位置更新公式为

$$X_{i,j}(\tau+1) = X_{\text{food}} \pm d_3 \times T_{\text{emp}} \times r \times (X_{\text{food}} - X_{i,j}(\tau)) \quad (14)$$

式中： $X_{i,j}$ 为蛇个体的位置； X_{food} 为蛇个体的最佳位置； d_3 取大值时可减小模型陷入局部最优的概率，本文取 2。

在开发阶段时，如果 $T_{\text{emp}} < 0.6$ ，蛇将处于战斗模式或交配模式。交配后若产生新个体，则替换掉

最差的雄、雌性并重新初始化。

为了获得最优故障诊断精度，本文需要借助蛇优化算法优化2个关键参数：

- 1) 输入的特征个数 b ，其取值范围为[1, 27]；
- 2) PAA分段步长 k ，其取值范围为[1, 1000]。

设置种群数量为 40，最大迭代次数为 40，其余参数为原算法中建议的默认值。

4 实验应用分析

4.1 振动信号采集

本文以 ZNJWV1-12kV 型号断路器作为研究对象，配备有 CT37-D 弹簧操动机构。在空载状态下，使用 LZ-601 型加速度传感器和 MPS-140801-M 混合型信号采集卡对高压断路器振动信号进行采集。其中，混合型信号采集卡的 5~8 通道为 IEPE 通道，内部具有电荷放大器，可直接与 IEPE 传感器相连，不需要额外的信号调理；实验装置如图 3 所示。

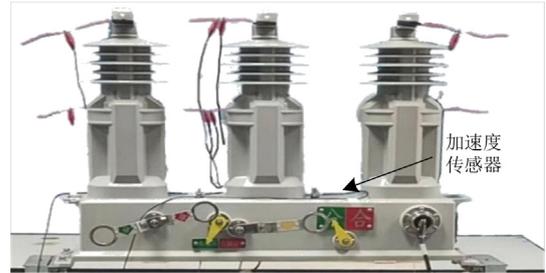


图 3 高压断路器实验装置

Fig. 3 Experimental device of high-voltage circuit breaker

由于加速度传感器安装位置的选择会影响振动信号的幅值和频率，对故障诊断研究至关重要。实验中传感器安装位置既要接近振源保证信噪比高，又要参考传感器量程和频率范围确保信号不削顶、不失真；经过多次实验对比分析，发现安装于断路器操动机构外壳上方表面位置时的信号幅值最为显著，可充分反映信号特征。其中，LZ-601 型加速度传感器参数如表 2 所示。

表 2 加速度传感器技术参数

Table 2 Technical parameters of acceleration sensor

参数名称	数值
频率范围/Hz	1~13 000
谐振频率/kHz	36
最大冲击加速度/(m/s ²)	5000
横向灵敏度/%	3.1
重量/g	17

由于高压断路器工作时长处于合闸状态，如果对断路器分闸信号进行故障诊断和状态评估，使其正确预警并可靠分闸，则对电网安全运行具有强

烈的现实意义, 因此本实验主要采集分闸信号并开展诊断分析。基于图 3 所示的实验装置, 本实验模拟了高压断路器的 7 种故障状态, 并采集包括正常状态在内的 8 种工况信号, 每种工况各 20 条, 共计 160 条样本数据, 如表 3 所示。

表 3 典型工况设置

类别	工况名称	设置情况
1	正常状态	—
2	底座螺丝松动	松动底座螺丝
3	缓冲器卡涩	调节缓冲器后移距离
4	铁芯垫片缺失	拆卸分闸电磁铁铁芯垫片
5	分闸线圈电压偏高	设置120%额定电压
6	分闸线圈电压偏低	设置80%额定电压
7	分闸弹簧疲劳	调节分闸弹簧张紧力
8	分闸弹簧脱落	摘除一个分闸弹簧

实验过程中使用 LabVIEW 平台界面实现波形显示和信号存储。经多次测量发现, 监测点信号频率不大于 13 kHz, 根据香农定理: 采样频率应等于或大于两倍信号频率。为充分采集信息, 设置采样频率为 64 kHz。

在断路器无动作时, 由于噪声和零点漂移的影响, 信号采集界面也会有微弱信号出现。为了防止采集装置误触发, 依据传感器失调电压值(当原边电流为 0 时, 失调最大值为 ± 60 mV)设置触发阈值电压为 60 mV。

采样时, 本实验使用 CHB-2AD 霍尔电流传感器判断分合闸线圈电流起始时刻, 设置触发负延时为 0.01 s, 即从电流起始前 0.01 s 时开始采集振动信号。正常状态下断路器分闸信号在 0.14 s 时趋于稳定, 但是在电压偏低、卡涩等情况发生时分闸信号时间会变长, 但不会超过 0.19 s, 因此设置触发正延时为 0.19 s, 总采样时间为 0.2 s。

4.2 实例验证

为了确保充分提取波形的重要特征(平均幅值)信息, 减少冗余信息的干扰。本实验在每种状态下采集的 20 条样本数据中随机抽取 70%(14 条)作为训练集建立故障诊断模型, 而其余 30%(6 条)作为测试集验证模型的性能, 以重复 20 次实验的平均正确率最高为目标, 并采用蛇优化算法诊断模型确定 PAA 分段步长和输入分类器的特征数量。经过寻优实验得出, 在分段步长 k 为 766, 输入分类器的特征数目 b 为 22 时, 平均正确率达到最高值(94.79% \pm 3.05%)。

当分段步长为 766 时, 8 种状态信号生成新序列, 再通过 GAF 转化得到灰度图, 如图 4 所示。图片从左上角到右下角对应递增的时间序列。

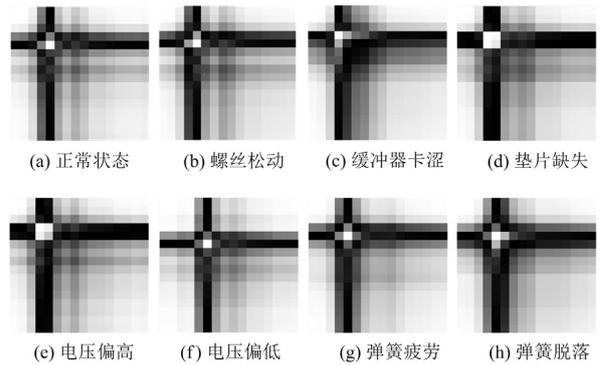


图 4 8 种状态转化的灰度图

Fig. 4 Converted grayscale image of eight states

从图 4 可以看出, 当高压断路器处于不同状态时, 其振动信号时序波形转化生成的灰度图片存在明显差异, 其主要区别在于图像颜色的深浅(各时间阶段幅值的大小)、十字交叉的位置(大冲击发生的时间)等。如电压偏低比电压偏高的时间延迟且撞击力度较小、波形幅值较低; 螺丝松动较正常状态的颜色深、撞击力度大、幅值高; 缓冲器卡涩状态下具有撞击持续时间长等特点; 垫片缺失颜色较深且振动衰减慢、持续时间长; 单个弹簧脱落较弹簧疲劳振动剧烈并持续时间长。上述差异说明了灰度图像能够清晰有效地反映断路器不同工况下的状态信息, 因此通过识别振动波形转化的灰度图, 可以实现对断路器的状态识别。

为了更全面地对高压断路器振动信号进行分析, 提取有效特征、去除冗余和无关特征以及提高分类器的分类性能和泛化能力, 本文采用 Relief F 特征选择方法对文中提取的 27 种特征进行重要度评价。选取重要度前 22 的特征为最优特征子集, 其重要度评价如表 4 所示。

为验证本文信号处理方法的优越性, 文中基于相同分类算法的前提下设置了基于不同信号处理方法的 3 组对比实验, 并对比分析其正确率。其中, 第 1 组将一维振动信号进行 3 层小波包变换^[23], 提取变换后的子带能量比和尺度熵特征并输入到 AdaBoost 集成分类模型。而第 2 组、第 3 组分别将振动信号进行经验模态分解^[22]和变分模态分解^[24], 根据模态中心频率间尽可能相距较远的原则分了 6 个本征模态, 并在时间分段上与本文实验方法 PAA 分段数量保持一致, 提取分段后各模态子带能量比特征, 随后采用 Relief F 方法进行特征重要度排序并输入到 AdaBoost 集成分类模型, 以正确率最高为优化目标, 使用蛇优化算法确定输入分类模型特征个数。最后, 将上述 3 组故障诊断模型与本文提

出的故障诊断模型准确率进行对比分析。上述各方法重复 20 次实验得到的平均故障诊断正确率如表 5 所示。

表 4 特征重要度排序

Table 4 Feature orders based on importance

特征	排序	特征	排序
T_1	20	T_{15}	26
T_2	15	T_{16}	22
T_3	10	T_{17}	11
T_4	25	T_{18}	17
T_5	8	T_{19}	21
T_6	6	T_{20}	24
T_7	14	T_{21}	4
T_8	3	T_{22}	12
T_9	23	T_{23}	18
T_{10}	9	T_{24}	13
T_{11}	19	T_{25}	1
T_{12}	27	T_{26}	16
T_{13}	7	T_{27}	2
T_{14}	5	—	—

表 5 不同诊断方法下正确率对比

Table 5 Accuracy comparison based on different fault diagnosis methods

序号	诊断方法	正确率/%
第1组	小波包变换+AdaBoost集成	64.58±2.23
第2组	经验模态分解+AdaBoost集成	92.19±3.08
第3组	变分模态分解+AdaBoost集成	93.02±4.58
本文方法	PAA-GAF+AdaBoost集成	94.79±3.05

由表 5 可知，本文所提方法具有最优准确率。由于第 1 组小波包方法只进行了频率分解而没有考虑时间分段，其诊断正确率相对较低，平均诊断精度仅为 64.58%。而第 2 组和第 3 组经验模态分解和变分模态分解方法既进行频率分解，又考虑时间分段，其诊断精度显著提高，平均诊断精度分别达到 92.19%和 93.02%。具体来说，高压断路器内部结构前后次序碰撞在振动信号波形上体现为先后不同的冲击，而每个冲击均需要在一定时间段内完成，且蕴含不同部位、不同种类的故障信息，因此对断路器振动信号进行时间分段可以更有效提取故障特征，有利于准确诊断。而第 3 组变分模态分解的非递归分解方式避免了包络误差造成的模态混叠问题，其处理信号相较于第 2 组经验模态分解更精准，正确率也更高。本文方法将振动信号转化为图片诊断精度更高，可达 94.79%，其主要原因是该方法不仅考虑了时间分段特性，同时通过将一维振动信号

转化为图片后信息量更为丰富，反映故障类型的特征维度更高，提取特征更为精确，进而提高了故障诊断精度，实验结果也进一步验证本文方法的有效性与可靠性。

由表 6 可知：断路器正常状态和底座螺丝松动诊断精度相对较低，缓冲器卡涩和分闸弹簧疲劳诊断效果最好。

表 6 不同工况正确率对比

Table 6 Accuracy comparison under different working conditions

类别	工况名称	正确率/%
1	正常状态	88.33±11.90
2	底座螺丝松动	85.83±14.21
3	缓冲器卡涩	100
4	铁芯垫片缺失	99.17±3.63
5	分闸线圈电压偏高	92.5±9.83
6	分闸线圈电压偏低	93.33±8.17
7	分闸弹簧疲劳	100
8	分闸弹簧脱落	99.17±3.63

为进一步验证本文分类方法 AdaBoost 集成算法的优越性，在基于本文信号处理方法的前提下，对比分析了 KNN、NB 和网络搜索优化支持向量机 (grid search optimized SVM, GS-SVM) 等方法与 AdaBoost 集成算法的诊断正确率，其中每个实验重复 20 次所得的平均诊断正确率如表 7 所示。

表 7 不同分类方法的诊断正确率对比

Table 7 Comparison of diagnosis accuracy of different classification methods

分类方法	正确率/%
KNN	91.25±3.64
NB	89.38±4.21
GS-SVM	93.77±3.10
AdaBoost集成	94.79±3.05

在数据样本较少时，SVM 的分类性能优越，但对参数表现敏感，因此使用 SVM 时需要优化参数，使其性能达到最优。由表 7 可知，虽然在单一分类器中 GS-SVM 分类精度最高，平均正确率为 93.77%，但是 AdaBoost 集成分类模型融合了 KNN、NB、LR 和 SVM 4 种单一分类器的优点，该集成分类模型的诊断性能均高于其他几种单一分类模型，平均正确率达到 94.79%，进一步验证了该集成分类方法可以准确处理高压断路器振动信号。

5 结论

针对振动信号复杂、维度高、波形随机及噪声强等特性，本文提出一种基于 PAA-GAF 振动信号

转图片的处理方法, 得到如下结论:

1) 使用 GGCM、GMRF 方法提取由振动信号转化为图信号的 27 维纹理特征, 相对于经验模态分解和变分模态分解、小波包分解一维信号方法, 能更有效地提取振动信号特征;

2) 采用 KNN、NB 和 GS-SVM 等方法与 AdaBoost 集成分类方法进行比较, AdaBoost 集成分类方法平均正确率均高于其他方法, 其平均正确率达到 94.79%±3.05%, 验证了集成分类方法的准确性;

3) 基于 PAA-GAF 振动信号处理和 AdaBoost 集成分类的高压断路器故障诊断方法能有效、准确地识别故障状态, 为断路器故障诊断提供了新思路。

本文使用的 PAA 方法在处理振动信号时无法根据信号特点自适应改变步长, 在更高效处理信号方面有一定局限性。后期工作将使分段步长结合高压断路器振动信号频率或信息熵等特点实现步长自适应改变, 提高信号处理效率。

参考文献

- [1] 段传宗, 鄢志平, 鄢志辉. 高压断路器故障检测与诊断技术[M]. 北京: 中国电力出版社, 2014.
- [2] 宋雷, 游东东, 郑振兴, 等. 基于经验模态分解的 RV 减压器运动参数降噪研究[J]. 振动与冲击, 2022, 41(18): 266-272, 290.
SONG Lei, YOU Dongdong, ZHENG Zhenxing, et al. Denoising of the kinetic parameters of a RV reducer based on an EMD algorithm[J]. Journal of Vibration and Shock, 2022, 41(18): 266-272, 290.
- [3] 张朝龙, 赵筛筛, 何怡刚. 基于集成经验模态分解与集成机器学习的锂离子电池剩余使用寿命预测方法[J]. 电力系统保护与控制, 2023, 51(13): 177-186.
ZHANG Chaolong, ZHAO Shaishai, HE Yigang. Remaining useful life prediction method for lithium-ion batteries based on ensemble empirical mode decomposition and ensemble machine learning[J]. Power System Protection and Control, 2023, 51(13): 177-186.
- [4] 杨德州, 刘嘉明, 宋汶秦, 等. 基于改进型自适应白噪声完备集成经验模态分解的工业用户负荷预测方法[J]. 电力系统保护与控制, 2022, 50(4): 36-43.
YANG Dezhou, LIU Jiaming, SONG Wenqin, et al. A load forecasting method for industrial customers based on the ICEEMDAN algorithm[J]. Power System Protection and Control, 2022, 50(4): 36-43.
- [5] 高淑萍, 徐振曦, 宋国兵, 等. 基于小波阈值去噪和 CEEMD 的混合三端直流输电线路故障测距[J]. 电力系统保护与控制, 2022, 50(3): 29-40.
GAO Shuping, XU Zhenxi, SONG Guobing, et al. Fault location of hybrid three-terminal HVDC transmission lines based on wavelet threshold denoising and CEEMD[J]. Power System Protection and Control, 2022, 50(3): 29-40.
- [6] 白浩, 潘姝慧, 邵向潮, 等. 基于小波去噪与随机森林的配电网高阻接地故障半监督识别方法[J]. 电力系统保护与控制, 2022, 50(20): 79-87.
BAI Hao, PAN Shuhui, SHAO Xiangchao, et al. A high impedance grounding fault semi-supervised identification method based on wavelet denoising and random forest[J]. Power System Protection and Control, 2022, 50(20): 79-87.
- [7] 王雪芹, 张大海, 李猛, 等. 基于小波能量谱和 SSA-GRU 的混合直流输电系统故障测距方法[J]. 电力系统保护与控制, 2023, 51(12): 14-24.
WANG Xueqin, ZHANG Dahai, LI Meng, et al. Fault location method for a hybrid DC transmission system based on wavelet energy spectrum and SSA-GRU[J]. Power System Protection and Control, 2023, 51(12): 14-24.
- [8] 杜太行, 孙靛, 孙曙光, 等. 深度残差网络在断路器故障诊断中的应用[J]. 仪表技术与传感器, 2022(7): 95-99.
DU Taihang, SUN Liang, SUN Shuguang, et al. Application of deep residual network in circuit breaker fault diagnosis[J]. Instrument Technique and Sensor, 2022(7): 95-99.
- [9] 鄢仁武, 林穿, 高硕勋, 等. 基于小波时频图和卷积神经网络的断路器故障诊断分析[J]. 振动与冲击, 2020, 39(10): 198-205.
YAN Renwu, LIN Chuan, GAO Shuoxun, et al. Fault diagnosis and analysis of circuit breaker based on wavelet time-frequency representations and convolution neural network[J]. Journal of Vibration and Shock, 2020, 39(10): 198-205.
- [10] 王丽华, 谢阳阳, 周子贤, 等. 基于卷积神经网络的异步电机故障诊断[J]. 振动、测试与诊断, 2017, 37(6): 1208-1215, 1283.
WANG Lihua, XIE Yangyang, ZHOU Zixian, et al. Motor fault diagnosis based on convolutional neural networks[J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(6): 1208-1215, 1283.
- [11] 杨秋玉, 阮江军, 黄道春, 等. 基于振动信号时频图像识别的高压断路器分闸缓冲器状态评估[J]. 电工技术学报, 2019, 34(19): 4048-4057.
YANG Qiuyu, RUAN Jiangjun, HUANG Daochun, et al. Opening damper condition evaluation based on vibration time-frequency images for high-voltage circuit breakers[J]. Transactions of China Electrotechnical Society, 2019, 34(19): 4048-4057.
- [12] 张艳飞, 邵阳, 公维炜, 等. 考虑小波包-灰度共生矩阵的高压断路器弹簧疲劳故障程度诊断研究[J/OL]. 机械科学与技术: 1-8[2022-11-10]. <https://doi.org/10.13433/j.cnki.1003-8728.20220199>.

ZHANG Yanfei, SHAO Yang, GONG Weiwei, et al. Research on the depth diagnosis of spring mechanical faults of high voltage circuit breakers considering wavelet packet-gray level co-occurrence matrix method[J/OL]. Mechanical Science and Technology for Aerospace Engineering: 1-8[2022-11-10]. <https://doi.org/10.13433/j.cnki.1003-8728.20220199>.

[13] 周建民, 黄熙亮, 熊文豪, 等. 基于可视图谱信号特征提取的滚动轴承故障诊断[J]. 制造技术与机床, 2022(9): 5-12.

ZHOU Jianmin, HUANG Xiliang, XIONG Wenhao, et al. Fault diagnosis of rolling bearing based on visual spectrum signal feature extraction[J]. Manufacturing Technology & Machine Tool, 2022(9): 5-12.

[14] 王潇笛, 刘俊勇, 刘友波, 等. 采用自适应分段聚合近似的典型负荷曲线形态聚类算法[J]. 电力系统自动化, 2019, 43(1): 110-118.

WANG Xiaodi, LIU Junyong, LIU Youbo, et al. Shape clustering algorithm of typical load curves based on adaptive piecewise aggregate approximation[J]. Automation of Electric Power Systems, 2019, 43(1): 110-118.

[15] 刘志坚, 何蔚, 刘航, 等. 基于格拉姆角场变换和深度压缩模型的变压器故障识别方法[J]. 电网技术, 2023, 47(4): 1478-1490.

LIU Zhijian, HE Wei, LIU Hang, et al. Fault identification method for power transformer based on Gramian angular field transformation and deep compression model[J]. Power System Technology, 2023, 47(4): 1478-1490.

[16] 洪继光. 灰度-梯度共生矩阵纹理分析方法[J]. 自动化学报, 1984(1): 22-25.

HONG Jiguang. Gray-gradient co-occurrence matrix texture analysis method[J]. Acta Automatica Sinica, 1984(1): 22-25.

[17] 王业琴, 王辉. GMRF 随机场在纹理特征描述与识别中的应用[J]. 计算机工程与应用, 2011, 47(25): 202-204, 219.

WANG Yeqin, WANG Hui. Application of rank GMRF in textural description and recognition[J]. Computer Engineering and Applications, 2011, 47(25): 202-204, 219.

[18] 邵阳, 武建文, 马速良, 等. 用于高压断路器机械故障诊断的 AM-Relief F 特征选择下集成 SVM 方法[J]. 中国电机工程学报, 2021, 41(8): 2890-2901.

SHAO Yang, WU Jianwen, MA Suliang, et al. Integrated SVM method with AM-Relief F feature selection for mechanical fault diagnosis of high voltage circuit breakers[J]. Proceedings of the CSEE, 2021, 41(8): 2890-2901.

[19] 唐贵基, 田寅初, 田甜. 基于 AlexNet-Adaboost 的多工况滚动轴承故障识别方法[J]. 振动与冲击, 2022, 41(2): 20-25.

TANG Guiji, TIAN Yinchu, TIAN Tian. Multi-working condition rolling bearing fault identification method based on the AlexNet-Adaboost algorithm[J]. Journal of Vibration and Shock, 2022, 41(2): 20-25.

[20] 徐耀松, 李佳旺, 段彦强. 基于相似度机制 AdaBoost-DBN 的变压器故障层级诊断[J]. 高压电器, 2023, 59(6): 154-164.

XU Yaosong, LI Jiawang, DUAN Yanqiang. Fault hierarchical diagnosis of transformer based on AdaBoost-DBN similarity mechanism[J]. High Voltage Apparatus, 2023, 59(6): 154-164.

[21] 逯浩坦, 伊力哈木·亚尔买买提, 刘鹏伟, 等. 基于 GWO-SVM 的高压断路器故障诊断[J]. 组合机床与自动化加工技术, 2022(1): 103-107.

LU Haotan, YILIHAMU·Yermainaiti, LIU Pengwei, et al. Fault diagnosis of high voltage circuit breaker based on GWO-SVM[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2022(1): 103-107.

[22] HASHIM F A, HUSSIEN A G. Snake optimizer: a novel meta-heuristic optimization algorithm[J]. Knowledge-Based Systems, 2022, 108320.

[23] 林婧, 张佳灏, 黎旭, 等. 基于振动信号的高压断路器螺栓松动故障诊断研究[J]. 高压电器, 2023, 59(3): 28-33.

LIN Jing, ZHANG Jiahao, LI Xu, et al. Research on bolt looseness of high voltage circuit breaker based on vibration signal[J]. High Voltage Apparatus, 2023, 59(3): 28-33.

[24] 李永刚, 丁其, 赵书涛. 基于变分模态分解的断路器机械故障诊断[J]. 电测与仪表, 2019, 56(20): 82-86, 107.

LI Yonggang, DING Qi, ZHAO Shutao. Circuit breaker mechanical fault diagnosis based on variational mode decomposition[J]. Electrical Measurement & Instrumentation, 2019, 56(20): 82-86, 107.

收稿日期: 2023-07-26; 修回日期: 2023-11-01

作者简介:

司江宽(1999—), 男, 硕士研究生, 研究方向为高压断路器故障诊断; E-mail: sjk@stu.xju.edu.cn

吐松江·卡日(1984—), 男, 通信作者, 博士, 副教授, 博士生导师, 研究方向为电力系统数字化技术、故障诊断与模式识别等。E-mail: tsj@xju.edu.cn

(编辑 姜新丽)