

DOI: 10.13382/j.jemi.B1902601

基于 CWD 及分块 SVD 的配电开关故障诊断方法*

王永明¹ 陈宇星¹ 殷自力¹ 李宽宏² 张振宇³ 高源³ 罗翔³ 高伟⁴

(1. 国网福建省电力有限公司 福州 350003; 2. 国网福建省电力有限公司福州供电公司 福州 350000;
3. 国网福建省电力有限公司电力科学研究院 福州 350007; 4. 福州大学电气工程与自动化学院 福州 350108)

摘要:通常,配电开关分合闸操作产生的振动信号中蕴含有关机械状态的重要信息。提出一种基于振动信号分析的新型配电开关故障诊断方法。首先对振动信号求取乔-威廉斯分布获得二维时频矩阵,然后对时频矩阵作分块奇异值分解,用于表征不同机械状态的时频特性,最后结合极限学习机算法对4类实测振动信号的特征向量进行训练和测试。所提方法的优点是有效提取了配电开关振动信号时频域的特征,并且可以在较少样本的情况下训练诊断模型。基于实测数据的实验表明,该方法具有较高的识别精度和较快的收敛速度。

关键词: 配电开关;机械状态识别;乔-威廉斯分布;分块奇异值分解;极限学习机

中图分类号: TM561; TN06 **文献标识码:** A **国家标准学科分类代码:** 470.40

Fault diagnosis method of power distribution switch via CWD and block SVD

Wang Yongming¹ Chen Yuxing¹ Yin Zili¹ Li Kuanhong²
Zhang Zhenyu³ Gao Yuan³ Luo Xiang³ Gao Wei⁴

(1. State Grid Fujian Electric Power Co., Ltd., Fuzhou 350003, China; 2. State Grid Fujian Electric Power Co., Ltd. Fuzhou Power Supply Company, Fuzhou 350000, China; 3. State Grid Fujian Electric Power Co., Ltd. Electric Power Research Institute, Fuzhou 350007, China; 4. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China)

Abstract: In general, vibration signals generated by the switching operation of a power distribution switch contains important information to reflect its mechanical status. A novel type of fault diagnosis method for a power distribution switch based on vibration signals analyses is proposed in this study. Firstly, the Choi-Williams distribution (CWD) for the vibration signal is calculated to obtain a two-dimensional time-frequency matrix. Then, the block singular value decomposition (BSVD) is performed on the two-dimensional time-frequency matrix, which is used to characterize the time-frequency characteristics of different mechanical states. Finally, the extreme learning machine (ELM) classification algorithm is adopted to train and test the feature vectors of four mechanical states of measured vibration signals. The advantages of the proposed method are that the time domain and frequency domain characteristics of vibration signals inside the power distribution switch are effectively extracted, and the diagnostic model can be trained without many samples. Experiments based on measured data show that the proposed method has a higher recognition accuracy with a faster convergent speed.

Keywords: distribution switch; mechanical state recognition; Choi-Williams distribution (CWD); block singular value decomposition (BSVD); extreme learning machine (ELM)

0 引言

配电开关是配电系统中十分重要的一次设备,控制电力设备的投入或退出运行,尤其是在电力设备发生故障时,配电开关接收继电保护装置信号,迅速切除故障部分,保证电力系统非故障部分正常运行^[1]。因此,保障配电开关的可靠动作可提高配网供电的可靠性。

机械特性不良是导致开关故障的主要原因,其中,操动机构故障占比很高。配电开关是瞬动式的电气设备,只有执行合闸或分闸命令时才处于动作状态。当其动作时,各组件依次动作、相互撞击,动作顺序具有一定的逻辑,由此产生短暂且强烈的冲击振动信号^[2]。由于振动信号是在电力、静电力和电磁力等多重激励下产生的,振源具有复杂性和多样性。因其非周期性、非线性等特点,难以直接识别不同的故障状态^[3]。因此,目前广泛采用信号分析工具获取特征表达,结合机器学习方法进行故障识别。

目前,对于振动信号的时频分析方面,小波包分析法^[4]、经验模态分解分析法^[5-6]、局部均值分解分析法^[7]和经验小波变换分析法^[8]在开关机械故障诊断领域受较多学者青睐,已取得一定的识别效果。但这些方法或多或少存在短板。如小波方法的最优小波基无法自适应选取;经验模态分解存在模态混叠和端点效应的问题,对于包含不同时间尺度的振动信号,分解后的分量不唯一,该方法的适应性有待提高。乔-威廉斯分布(Choi-Williams distribution, CWD)^[9]是一种适用于非平稳、非线性信号的时频分析方法,已被广泛应用于齿轮故障特征提取^[10]、电力系统接地故障诊断^[11]、脑电异常信号检测^[12]等领域。

信号时频变换后所提取的特征量主要有样本熵^[13]、功率谱熵^[14]、信息熵^[15]等统计量,但是这些统计量的计算结果易受扰动和噪声的影响,而达不到最佳的特征值。奇异值分解(singular value decomposition, SVD)^[16]通过降维实现矩阵重要特征的抽取,节省运行空间和时间,在含有噪声和扰动的背景中,奇异值分解的特征计算稳定性高,因此广泛应用于图像处理、数据压缩和降噪等研究方向。

在模式识别方面,开关故障分类主要依靠支持向量机(SVM)^[8]、模糊 c-均值聚类^[3]、相关向量机(RVM)^[13]和专家系统^[17]等方法。其中,支持向量机和相关向量机虽然在小样本、高维度及非线性的分类问题中优势明显^[18],但其基于“二叉树”结构的分类过程,使得模型训练时间长,且无法同时实现多类样本分类。极限学习机(extreme learning machine, ELM)^[19]是一种新型的快速学习算法,解决了传统前馈神经网络的学习速度缓慢、易陷入局部极小值和易出现过拟合训练等问题,适用于数据多分类。

本文提出一种采用 CWD 及分块 SVD 的配电开关故

障诊断方法。首先采用 CWD 获取配电开关振动信号的时频矩阵;再结合分块奇异值分解方法获取能够表征信号本质特征的奇异值矩阵;然后构造奇异值向量作为 ELM 的样本,进行模型的训练和测试。

1 方法的提出

1.1 基于乔-威廉姆斯分布的信号分解

振动信号对测量环境较为敏感,易受周围噪声影响,测量信号往往是多分量信号的叠加。若将一维时域信号变换到二维的时频平面,时频分析可挖掘信号内部的局部特征和信息。为了得到时变非平稳多信号的时频谱特性,许多学者提出了各种形式的时频分布函数,从短时傅里叶变换到 Wigner-Ville 分布(WVD)再到 Cohen 类分布,对于信号在不同时间和频率的能量密度的描述能力愈来愈强。WVD 虽然具有大部分时频分析函数所希望的数学性质,但亦会产生所谓的“交叉项干扰”,影响检测精度。为解决这个问题,各式各样的核函数被用于改进 WVD,统称为 Cohen 类分布。具有指数型核函数的 CWD 是 Cohen 类分布的一种,在所有未经处理的 Cohen 类分布中,具有交叉项干扰最小的特点,对于多分量信号具有较高的分辨能力和识别精度。

对于非平稳复信号 $x(t)$,其 CWD 分布为:

$$C_x(t, \omega) = \int_{\tau=-\infty}^{\infty} e^{-j\omega\tau} \int_{u=-\infty}^{\infty} \frac{1}{\sqrt{4\pi\tau/\alpha}} e^{-\frac{(u-t)^2}{4\tau^2/\alpha}} x\left(u + \frac{\tau}{2}\right) x^*\left(u - \frac{\tau}{2}\right) du d\tau \quad (1)$$

式中: t 是时间; ω 为角频率; τ 为时移参数; u 是局部时间; α 为平滑因子; x^* 是 x 的卷积。

对式(1)作离散化处理,并加窗,则式(1)可变为:

$$C_x(l, \omega) = 2W(n) \sum_{n=-\infty}^{\infty} S(l, n) e^{-j2\omega n} \quad (2)$$

$$S(l, n) = W(u) \sum_{u=-M/2}^{M/2} \left(\frac{1}{\sqrt{4\pi\tau^2/\alpha}} \cdot e^{-\frac{(u-l)^2}{4\tau^2/\alpha}} \cdot x(u+n)x^*(u-n) \right) \quad (3)$$

式中: l 是时刻点; n 是时移参数; $W(n)$ 是对称窗,窗口范围为 $-N/2 \sim N/2$,在此区间具有非零值; $W(u)$ 是矩形窗,窗口范围为 $-M/2 \sim M/2$,在此区间的值均为 1。 N 和 M 的取值分别决定了 CWD 的频率分辨率和函数的定义域。

振动信号表示为 $v(d)$, d 为采样点数。其 CWD 时频矩阵的求取步骤如下。

1) 对 $v(d)$ 按式(4)作 Hilbert 变换。

$$H[v(d)] = \sum_{k=1}^d h(k) e^{-j\omega k} \quad (4)$$

式中: ω 为角频率。由此构造出相应的复信号 $Y(d)$:

$$Y(d) = v(d) + jH[v(d)] = v(d) + j \sum_{k=1}^d h(k) e^{-j\omega k} \quad (5)$$

2) 由式(2)和(3)求复信号 $Y(d)$ 的 CWD 分布, 得二维时频矩阵 \mathbf{A} , 如式(6)所示, 其大小为 $d \times d$ 。

$$\mathbf{C} = \begin{bmatrix} c_{11} & c_{12} & \cdots & c_{1d} \\ c_{21} & c_{22} & \cdots & c_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ c_{d1} & c_{d2} & \cdots & c_{dd} \end{bmatrix} \quad (6)$$

\mathbf{A} 对应的频率向量 \mathbf{f} 和时间向量 \mathbf{t} 分别为:

$$\begin{aligned} \mathbf{f} &= [1, 2, 3, \dots, d] \cdot f_s/2 \\ \mathbf{t} &= [1, 2, 3, \dots, d] \cdot \frac{1}{f_s} \end{aligned} \quad (7)$$

式中: f_s 是采样频率。

对 CWD 分解结果的分析往往采用等高图形式给出。图 1 所示为某信号经过 CWD 分解后的等高图, 横坐标代表时间, 纵坐标代表频率, 颜色代表幅值大小, 颜色由蓝到红的渐变表示能量从小到大的变化。从图 1 可以看出, 该信号在中高频段的能量基本为 0, 低频段的能量比较大, 且集中分布在某个频段上。高压断路器不同的机械故障类型, 其能量在不同的频段上呈现不一样的分布特征, 而相同的故障类型又往往存在相同的分布特征, 这样的分布规律比较适合用 CWD 来进行刻画。




图 1 用等高图表示的 CWD 分解结果

Fig. 1 CWD decomposition result expressed by contour map

1.2 分块奇异值分解

任一矩阵都可以表示为一系列秩为 1 的“小矩阵”的迭加, 而奇异值用于衡量这些“小矩阵”对于原矩阵的

权重。在矩阵元素发生小干扰时, 其奇异值变化较小, 具有很强的稳定性。

假设 \mathbf{A} 是一个 $m \times n$ 的矩阵, 定义 \mathbf{A} 的 SVD 为:

$$\mathbf{A} = \mathbf{U} \mathbf{X} \mathbf{V}^T \quad (8)$$

式中: \mathbf{U} 是一个 $m \times m$ 的方阵, 各列向量相互正交; \mathbf{X} 是一个 $m \times n$ 的方阵, 除了对角线元素都是 0, 对角线上的元素称为奇异值; \mathbf{V}^T (\mathbf{U} 的转置) 是一个 $n \times n$ 的方阵, 各列向量相互正交。对式(8)进行特征分解, 得到特征值和特征向量。

$$(\mathbf{A}^T \mathbf{A}) \mathbf{v}_i = \lambda_i \mathbf{v}_i \quad (9)$$

$$\mathbf{u}_i = \frac{1}{\sqrt{\lambda_i}} \mathbf{A} \mathbf{v}_i \quad (10)$$

式中: \mathbf{v}_i ($i=1, 2, \dots, n$) 是矩阵 \mathbf{V} 的各行向量; λ_i ($i=1, 2, \dots, r$) 是矩阵 $\mathbf{A}^T \mathbf{A}$ 的特征值, r 是矩阵 $\mathbf{A}^T \mathbf{A}$ 的秩; \mathbf{u}_i ($i=1, 2, \dots, m$) 是矩阵 \mathbf{U} 的各列向量。

对二维时频矩阵直接进行奇异值分解, 虽能降阶且省时, 但是, 对于振动信号, 其时频矩阵能量突变值通常集中于某些时刻点, 而分解得到的奇异值按照值从大到小排列, 无法精确反映能量变化的特点和趋势。采用分块奇异值分解方法, 不仅可反映不同类型振动信号的能量大小, 而且可表达能量变化的时刻, 步骤如下。

1) 对二维时频矩阵进行分块, 得到 r 个 $(d/\sqrt{r}) \times (d/\sqrt{r})$ 的小方阵。

2) 分别对这些小方阵进行奇异值分解, 得到 r 个大小为 $1 \times (d/\sqrt{r})$ 的奇异值向量。

3) 将这 r 个向量按照一定顺序拼接, 得到 1 个大小为 $r \cdot d/\sqrt{r}$ 的特征奇异值向量。

对二维时频矩阵 \mathbf{C} 的特征向量提取过程如图 2 所示, 分别经历了分块, SVD 求解以及拼接过程, 每个分块小矩阵 \mathbf{A}_k 大小为 $m \times m$, $k=(1, 2, \dots, r)$ 。 \mathbf{A}_k 经奇异值分解后, 得到的奇异值向量为:

$$\mathbf{a}_k = [\sqrt{\lambda_1}, \sqrt{\lambda_2}, \dots, \sqrt{\lambda_m}] \quad (11)$$

将所有的分块小矩阵的奇异值向量按行拼接, 形成如式(12)的结构, 构成所提方法的特征向量。

$$[\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_k, \dots, \mathbf{a}_{m-1}, \mathbf{a}_m] \quad (12)$$

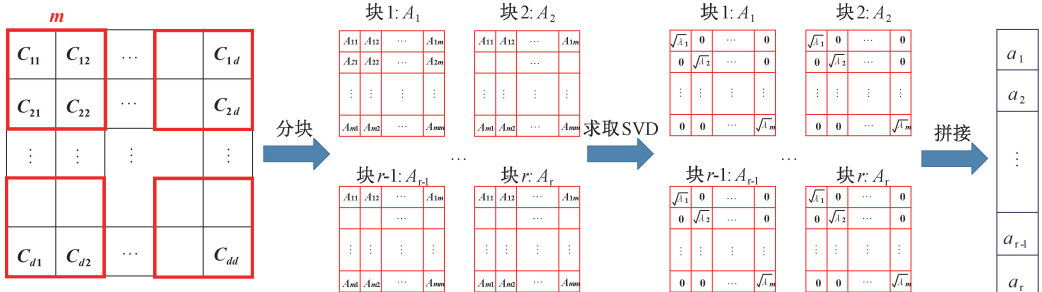


图 2 特征向量提取过程

Fig. 2 Extraction process of feature vectors

1.3 极限学习机分类

极限学习机是从单隐层前馈神经网络发展而来的算法。算法随机产生输入层与隐含层间的连接权值及隐含层神经元的阈值,且在训练过程中无需调整,只需要设置隐含层神经元的个数,便可以获得唯一的最优解。

如图3所示,输入层 x 、隐含层 g 和输出层 y 构成了极限学习机的基本网络结构。设输入信号的向量元素个数为 n ,则网络输入层需设置 n 个神经元,设隐含层神经元个数取值为 h ,输出层神经元个数为 m 。则输入层与隐含层的连接权值矩阵可表示为:

$$W = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1i} & \cdots & w_{1n} \\ w_{21} & w_{22} & \cdots & w_{2i} & \cdots & w_{2n} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ w_{j1} & w_{j2} & \cdots & w_{ji} & \cdots & w_{jn} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ w_{h1} & w_{h2} & \cdots & w_{hi} & \cdots & w_{hn} \end{bmatrix}_{h \times n} \quad (13)$$

式中: w_{ji} 为输入层第 i 个神经元与隐含层第 j 个神经元的连接权值。




图3 ELM结构

Fig. 3 Structure of ELM

隐含层和输出层的连接权值矩阵可表示为:

$$\mu = \begin{bmatrix} \mu_{11} & \mu_{12} & \cdots & \mu_{1j} & \cdots & \mu_{1h} \\ \mu_{21} & \mu_{22} & \cdots & \mu_{2j} & \cdots & \mu_{2h} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \mu_{k1} & \mu_{k2} & \cdots & \mu_{kj} & \cdots & \mu_{kh} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \mu_{m1} & \mu_{m2} & \cdots & \mu_{mj} & \cdots & \mu_{mh} \end{bmatrix}_{m \times h} \quad (14)$$

式中: μ_{kj} 为隐含层第 j 个神经元与输出层第 k 个神经元的连接权值。

隐含层的阈值矩阵可表示为:

$$\eta = [\eta_1, \eta_2, \cdots, \eta_h]^T \quad (15)$$

训练过程中,设极限学习机的输入样本集包含的样本个数为 e , X 为输入矩阵, Y 为样本标签矩阵。其表达

式为:

$$X = [x_1^T, x_2^T, \cdots, x_e^T]_{n \times e} \quad (16)$$

$$Y = [y_1^T, y_2^T, \cdots, y_e^T]_{m \times e}$$

式中: x 代表式(12)的特征向量,下标 $1, 2, \cdots, e$ 表示样本编号; y 为样本标签, m 为目标类型数,其值如表1所示。

表1 样本标签分布

Table 1 Sample label distribution

分类名称	类型标签 y
类型1	1, 0, \cdots , 0
类型2	0, 1, \cdots , 0
\vdots	
类型 m	0, 0, \cdots , 1

在网络训练之前,对样本的特征量矩阵 X 按行做归一化处理:

$$x'_{ij} = \frac{(x'_{\max} - x'_{\min})(x'_{ij} - \min(X_i))}{\max(X_i) - \min(X_i) + x'_{\min}} \quad (17)$$

式中: x'_{\max} 与 x'_{\min} 为指定的归一化区间边界值; $\min(X_i)$ 表示求矩阵 X 第 i 行的最小值; $\max(X_i)$ 表示求矩阵 X 第 i 行的最大值。

若极限学习机的激活函数为,则训练网络的输出矩阵可表示为:

$$O = [o_1, o_2, \cdots, o_j, \cdots, o_e]_{m \times e}$$

$$o_j = [o_{1j}, o_{2j}, \cdots, o_{mj}]^T = \begin{bmatrix} \sum_{i=1}^h \mu_{i1} f(w_i x_j + \eta_i) \\ \sum_{i=1}^h \mu_{i2} f(w_i x_j + \eta_i) \\ \vdots \\ \sum_{i=1}^h \mu_{im} f(w_i x_j + \eta_i) \end{bmatrix}$$

$$j = 1, 2, \cdots, e \quad (18)$$

式中: w_i 为矩阵 W 的第 i 行; x_j 为矩阵 X 的第 j 列。式(18)可简写为:

$$H\mu = O^T$$

$$H = \begin{bmatrix} f(w_1 \cdot x_1 + \eta_1) & \cdots & f(w_h \cdot x_1 + \eta_h) \\ \vdots & \vdots & \vdots \\ f(w_1 \cdot x_e + \eta_1) & \cdots & f(w_h \cdot x_e + \eta_h) \end{bmatrix}_{e \times h} \quad (19)$$

当选取的激活函数 $f(x)$ 无限可微时,权值 W 和阈值 η 可以随机设定,输出层权值可计算如下:

$$\hat{\mu} = H^+ O^T \quad (20)$$

式中: H^+ 表示矩阵 H 的广义逆矩阵。

1.4 配电开关故障诊断模型训练流程

本文提出了一种新型的配电开关故障诊断方法,模型训练流程如下。

- 1) 以一定的采样频率采集配电开关在不同机械状态动作时的振动信号,对信号进行前处理,如截取合适的片段。
- 2) 将振动信号进行 Hilbert 变换,构造相应的复信号,随后进行 CWD 时频分解,获得二维时频矩阵。
- 3) 将时频矩阵分块依次进行奇异值分解,并连接成一维向量,形成特征向量。
- 4) 将特征量随机分为训练样本集和测试样本集,设置 ELM 隐含层神经元个数及激活函数,进行神经网络的训练和测试。

2 实验结果与讨论

2.1 故障实验介绍

故障样本采集自型号为 ZN63 A-12(VS1)的户内高压交流真空断路器,操动机构为弹簧储能式。采集振动信号的压电加速度传感器的型号为 LC0102T,选用 NI 公司的 USB-6211 型多功能数据采集模块。实验过程中将传感器安装在靠近 C 相触头轴线的断路器外壳底部,使之采集到距离振源最近的信号。真空断路器分合闸时都会产生振动,合闸时的振动强度大于分闸,因此本研究以合闸时产生的振动信号作为研究对象。

振动信号采集装置如图 4 所示。采样频率设定为 9 kHz,为了减小传感器的零度漂移影响,设定一定的冲击启动阈值,截取启动前 15 ms 与之后的 96 ms 波形(共 1 000 个点)作为有效数据样本。共检测了 4 种状态下的振动信号,分别是正常状态、轴销异常状态,脱扣装置卡涩状态、轴承合闸卡涩状态,样本分布如表 2 所示。按照前述方法进行 CWD 分解、分块奇异值分解后,将二维 CWD 时频矩阵作 100 等分,即时间轴和频率轴方向各进行 10 等分,每个小方块的大小为 100×100。



图 4 振动信号采集装置

Fig. 4 Field acquisition device for vibration signals

表 2 振动信号样本分布		
Table 2 Sample distribution of vibration signal		
机械状态	训练样本	测试样本
正常状态	182	45
轴销异常	182	45
脱扣装置卡涩	182	45
轴承卡涩	182	45
合计	728	180

2.2 实验结果分析

1) 激活函数类型对 ELM 预测结果的影响

在前馈神经网络中,激活函数的作用是保留输入样本特征并加以映射。因此,激活函数的选取影响 ELM 网络隐含层特征表达程度,进而影响输出结果。网络的均方误差可体现算法预测结果的准确率,输出值越低,算法预测准确率越高。本文选取 3 种 ELM 中常用的激活函数,进行对比分析,分别为 sigmoid 函数、hardlim 函数和 sin 函数。为了减小网络的初始参数随机性的影响,每种激活函数的实验结果均取 5 次实验结果的平均值。

如图 5 所示,随着隐含层神经元个数的增加,以 sigmoid、hardlim 为激活函数的 ELM 的均方误差逐渐降低,趋于平稳,识别准确率高;而以 sin 为激活函数的 ELM 出现了均方误差不断波动的结果,且值高于前者。综合考虑训练速度和识别精度,选择 sigmoid 函数作为 ELM 网络的激活函数。




图 5 激活函数对 ELM 性能的影响

Fig. 5 Effect of activation function on the performance of ELM

2) 隐层神经元数目对 ELM 预测结果的影响

隐含层神经元个数的选取会影响 ELM 最终的识别效果。因此,令其从 $N/10$ 开始,以步长为 $N/10$ 逐渐增加至 N ,探究隐层神经元最佳个数值。 N 为样本长度,本实验中取 10 000。由于输入层与隐含层间的连接权值及隐含层神经元的阈值是随机产生的,因此,重复上述实验 5 次,测试集预测正确率变化曲线如图 6 所示。在隐含层神经元个数较多时,所绘曲线之间的分散性很小,说明 ELM 模型的稳定性高。但是,并非是隐含层神经元个数

越多,测试集预测正确率越高。在隐含层神经元个数为 6 000、7 000 时,预测正确率呈逐渐减小的趋势。综合考虑计算速度与预测精度,将隐含层神经元个数定为 5 000。




图 6 隐含层神经元个数的影响

Fig. 6 Effect of number of neurons in the hidden layer

3) 模型测试结果

运用上述所提方法及参数构建配电开关故障诊断模型,训练集样本为 728 个,辨识准确率为 100%。对 180 个测试集样进行测试,测试结果如表 3 所示。有 3 个正常状态的数据样本被错分成脱扣装置卡涩。轴销异常的数据样本则都识别正确。脱扣装置卡涩的数据样本中有 2 个被误认为正常状态,有 1 个误认为轴承卡涩。轴承卡涩的数据样本亦有 2 个误认为轴销异常,有 1 个误认为脱扣装置卡涩。整体识别准确率为 95%,这表明了所提方法具有极高的辨识准确率。

表 3 各类振动信号测试集测试情况

机械状态	测试样本	测试正确个数	识别正确率/%
正常状态	45	42	93.3
轴销异常	45	45	100
脱扣装置卡涩	45	42	93.3
轴承卡涩	45	42	93.3
合计	180	171	95

4) 算法中的优化组合性能评价

为验证所述算法中各种组合的性能,将其与其他组合进行对比。方法 1 为本文所用方法;方法 2 将方法 1 中的分块 SVD 替换为直接对 CWD 时频矩阵做 SVD,依然用 ELM 分类;方法 3 为获得时频矩阵后,求边际谱,后用 ELM 分类。对于分类器的对比分析,主要考虑与较广泛采用的 SVM 进行对比,特征量仍沿用本文提取的特征量,将该方法记为方法 4。

将上述 4 种方法在配置了 Intel® Xeon W-2123 (3.60 GHz×8) CPU, 32 GB 内存和 64 位 win10 操作系统的电脑中执行,从运行结果(表 4)上看,与直接求奇异值相比,分块 SVD 的识别正确率提升了 12.8%,说明分块

SVD 可以进一步放大非同类机械状态的特征的差异性,提高辨识准确度。方法 3 尽管和方法 1 用了同类的分类器,但是特征向量的提取方式不同。可以清楚地发现,采用的 CWD 加分块 SVD 方法提取的特征量辨识度明显优于采用边际谱提取的特征量。在特征量元素个数较多的情况下,采用线性核函数的 SVM 识别精度明显低于 ELM,且运行时间远大于 ELM。由于方法 2 和方法 3 的特征量个数比方法 1 小 1/10,因此测试集的总耗时比方法 1 小很多,这恰恰也说明 ELM 的执行时间非常快。

表 4 四种方法的分类正确率

Table 4 Classification accuracy of the four methods				
选用方法	训练准 确率/%	测试准 确率/%	训练集总 耗时/s	测试集总 耗时/s
方法 1	100	95.00	1.28	0.54
方法 2	83.10	82.22	0.02	0.008
方法 3	90.25	74.44	0.02	0.07
方法 4	—	26.11	5.47	27.8

2.3 与其他算法对比

为了验证所提算法的性能,在分类准确率指标上和其他方法进行对比。文献[20]提出一种基于变分模态分解(VMD)和多层分类器的高压断路器机械故障诊断方法。首先,VMD 算法用于将振动信号分解成若干固有模式函数(IMF)。其次,将 IMF 矩阵分成若干子矩阵并计算局部奇异值。最后,构造一个由两个一类支持向量机(OCSVM)和一个支持向量机组成的多层分类器来辨识故障类型。文献[21]通过小波包和能量熵来提取振动信号的特征值,使用粒子群优化的 BP 神经网络作为分类器。

表 5 三种方法的分类正确率

Table 5 Classification accuracy of the three methods			
状态	本文	文献[20]	文献[21]
正常状态	42*/45*2	42/45	28/45
轴销异常	45/45	43/45	40/45
脱扣装置卡涩	42/45	41/45	35/45
轴承卡涩	42/45	39/45	30/45
准确率/%	95.00	91.67	73.89

注: *1 代表辨识正确样本数量; *2 代表总样本数量

同样,用 728 个样本进行训练,用 180 个样本进行测试,测试结果如表 5 所示。本文所提方法的准确率最高,文献[20]次之,文献[21]最差。从单一类别上看,轴销异常在每种算法中的辨识度都优于其他类别,说明该类型的故障特征变化较为显著。

综上所述,本文所述方法兼顾识别精度和分类识别算法的训练速度,在配电开关机械故障识别的问题上达到一个上佳的效果。本文同样也对配电开关的分闸信号进行特征提取和分类识别,但实验结果显示测试集识别正确率不超过 70%,这是因为配电开关分闸操作没有触

头的碰撞事件,导致分闸振动的幅值比合闸碰撞产生的振动小,易受噪声影响。因此,选取合闸信号作为故障识别的研究素材较为合适。

3 结 论

运用 CWD 和分块 SVD 对配电开关振动信号进行特征量提取,得到四类不同的机械状态振动信号的分块奇异值向量;采用 ELM 对提取的特征量进行学习和预测,理论分析和实验结果均表明,利用 CWD 时频分析方法,可直接获得信号的时频矩阵,相比其他算法如 HHT,在处理信号之后,需通过带通滤波等方可获得时频矩阵。因此,用 CWD 构造时频矩阵更为便捷;分块 SVD 方法可以更深入地刻画时频矩阵在时域和频域的特征信息,相比时频矩阵直接求取奇异值的方法,准确率提高 12.8%,说明分块 SVD 获得的特征辨识度更高;利用 ELM 作为识别方法,提高了配电开关机械故障识别的速度和精度,且所需样本数量较少。

参考文献

- [1] 吕超,于洪海,王立欣. 基于人工免疫网络的断路器在线自学习故障诊断[J]. 中国电机工程学报, 2009, 29(34):128-134.
LU CH, YU H H, WANG L X. On-line self-learning fault diagnosis for circuit breakers based on artificial immune network[J]. Proceedings of the CSEE, 2009, 29(34):128-134.
- [2] 高伟,杨耿杰,郭谋发,等. 采用振动信号二维特征向量聚类的配电开关机械状态识别新方法[J]. 福州大学学报, 2017,45(5):674-680.
GAO W, YANG G J, GUO M F, et al. A novel mechanical state identification method for distribution switch based on vibration signal 2-D feature vector with cluttering algorithm[J]. Journal of Fuzhou University, 2017,45(5):674-680.
- [3] 郭谋发,徐丽兰,缪希仁,等. 采用时频矩阵奇异值分解的配电开关振动信号特征量提取方法[J]. 中国电机工程学报, 2014,34(28):4990-4997.
GUO M F, XU L L, MIAO X R, et al. A vibration signal feature extraction method for distribution switches based on singular value decomposition of time-frequency matrix[J]. Proceeding of the CSEE, 2014, 34(28):4990-4997.
- [4] 赵书涛,王亚潇,孙会伟,等. 基于自适应权重证据理论的断路器故障诊断方法研究[J]. 中国电机工程学报, 2017,37(23):7040-7046.
ZHAO SH T, WANG Y X, SUN H W, et al. Research of circuit breaker fault recognition method based on adaptive weighted of evidence theory[J]. Proceeding of the CSEE, 2017,37(23):7040-7046.
- [5] LIU M, WANG K, SUN L, et al. Applying empirical mode decomposition (EMD) and entropy to diagnose circuit breaker faults [J]. Optik, 2015, 126 (20): 2338-2342.
- [6] 何怡刚,陶琳,施天成,等. 基于改进 BREMD 与 ELM 的断路器机械故障诊断[J]. 电子测量技术, 2018, 41(21):81-88.
HE Y G, TAO L, SHI T CH, et al. Mechanical fault diagnosis of circuit breaker based on improved BREMD and ELM [J]. Electronic Measurement Technology, 2018, 41(21):81-88.
- [7] 孙曙光,张强,杜太行,等. 基于灰色关联度的框架式断路器故障诊断方法[J]. 仪器仪表学报, 2017(10):2525-2535.
SUN SH G, ZHANG Q, DU T H, et al. Fault diagnosis method of frame-type circuit breaker based on grey correlation degree [J]. Chinese Journal of Scientific Instrument, 2017(10):2525-2535.
- [8] 焦晓璇,景博,李娟,等. 基于 ADEGW-SVM 的机载燃油泵寿命预测研究[J]. 仪器仪表学报, 2018, 39(8):43-54.
JIAO X X, JING B, LI J, et al. Research on remaining useful life prediction of fuel pump based on adaptive differential evaluation grey wolf optimizer-support vector machine[J]. Chinese Journal of Scientific Instrument, 2018,39(8):43-54.
- [9] XIANG M, WANG Z, LIU J. Extracting array acoustic logging signal information by combining fractional Fourier transform and Choi-Williams distribution [J]. Applied Acoustics, 2015, 90: 111-115.
- [10] 王卫国,孙磊. 基于 EEMD-CWD 的齿轮箱振动信号故障特征提取 [J]. 兵工学报, 2014, 35 (8): 1288-1294.
WANG W G, SUN L. Gearbox Vibration signal fault feature extraction based on ensemble empirical mode decomposition and choi-williams distribution [J]. Acta Armamentarii, 2014, 35(8): 1288-1294.
- [11] GHADERI A, MOHAMMADPOUR H A, GINN H L, et al. High-impedance fault detection in the distribution network using the time-frequency-based algorithm [J]. IEEE Transactions on Power Delivery, 2015, 30 (3): 1260-1268.
- [12] ALAZRAI R, AL-RAWI S, ALWANNI H, et al. Tonic cold pain detection using choi-williams time-frequency distribution analysis of EEG signals: A feasibility study[J]. Applied Sciences, 2019, 9(16): 3433.

- [13] 孙曙光, 于晗, 杜太行, 等. 基于振动信号样本熵和相关向量机的万能式断路器分合闸故障诊断[J]. 电工技术学报, 2017, 32(7): 20-30.
- SUN SH G, YU H, DU T H, et al. Diagnosis on the switching fault of conventional circuit breaker based on vibration signal sample entropy and RVM [J]. Transactions of China Electrotechnical Society, 2017, 32(7): 20-30.
- [14] 孙曙光, 于晗, 杜太行, 等. 基于多特征融合与改进QPSO-RVM的万能式断路器故障振声诊断方法[J]. 电工技术学报, 2017, 32(19): 107-117.
- SUN SH G, YU H, DU T H, et al. Vibration and acoustic joint fault diagnosis of conventional circuit breaker based on multi-feature fusion and improved QPSO-RVM[J]. Transactions of China Electrotechnical Society, 2017, 32(19): 107-117.
- [15] 常广, 王毅, 王玮. 采用振动信号零相位滤波时频熵的高压断路器机械故障诊断[J]. 中国电机工程学报, 2013, 33(3): 155-162.
- CHANG G, WANG Y, WANG W. Mechanical fault diagnosis of high voltage circuit breakers utilizing zero-phase filter time-frequency entropy of vibration signal [J]. Proceeding of the CSEE, 2013, 33(3): 155-162.
- [16] 高伟, 陈伟凡, 杨耿杰, 等. 基于奇异值分解和多级支持向量机的配电网故障类型识别[J]. 电子测量与仪器学报, 2018, 32(2): 62-71.
- GAO W, CHEN W F, YANG G J, et al. Fault type identification for distribution network based on singular value decomposition and multi-level support vector machine [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(2): 62-71.
- [17] HUSSAIN A, LEE S, CHOI M, et al. An expert system for acoustic diagnosis of power circuit breakers and on-load tap changers[J]. Expert Systems with Applications, 2015, 42(24): 9426-9433.
- [18] 洪翠, 杨华锋, 卢国仪, 等. 基于振动信号 SVM 分类的配变故障识别方法[J]. 仪器仪表学报, 2016, 37(6): 1299-1308.
- HONG C, YANG H F, LU G Y, et al. Fault identification method for distribution transformer based on

SVM classification of vibration signal [J]. Chinese Journal of Scientific Instrument, 2016, 37 (6): 1299-1308.

- [19] 孟凡煦, 张琰骏. 基于 VMD 和 ELM 的超短期负荷预测方法[J]. 国外电子测量技术, 2019, 38(1): 29-33.
- MENG F X, ZHANG Y J. Ultra short-term load forecasting method based on VMD and ELM[J]. Foreign Electronic Measurement Technology, 2019, 38 (1): 29-33.
- [20] HUANG N T, CHEN H J, CAI G W, et al. Mechanical fault diagnosis of high voltage circuit breakers based on variational mode decomposition and multi-layer classifier[J]. Sensors, 2016, 16(11): 1887.
- [21] LIU S, TAN J, MENG F G, et al. Study of PSO-BP neural networks application in high-voltage circuit breakers mechanical fault diagnosis [C]. 2016 China International Conference on Electricity Distribution (CICED). IEEE, 2016: 1-5.

作者简介



王永明, 2006 年于清华大学获得硕士学位, 现为国网福建省电力有限公司高级工程师, 主要研究方向为电力系统自动化。

E-mail: 31334323@qq.com

Wang Yongming received his M. Sc. degree from Tsinghua University in 2006. Now he is a senior engineer in State Grid Fujian Electric Power Co., Ltd. Fuzhou, China. His main research interest includes electric power engineering with its automation.



张振宇 (通信作者), 2016 年于英国巴斯大学获得博士学位, 2017 年于美国佛罗里达州立大学开展博士后课题研究。主要研究方向为配电网自动化技术、超导直流配电网等。

E-mail: 823976250@qq.com

Zhang Zhenyu (Corresponding author) received his Ph. D. degree from the University of Bath, UK in 2016, conducted post-doctoral research at Florida State University, USA in 2017. His main research interests include automation of distribution network, Superconducting direct-current distribution network.