

# 基于 VMD 和样本熵的电磁式电流互感器故障诊断

唐登平<sup>1</sup>, 蔡文嘉<sup>1</sup>, 周翔宇<sup>2</sup>, 李云峰<sup>1</sup>, 郭正<sup>1</sup>, 刘岑岑<sup>1</sup>

(1. 国网湖北省电力有限公司计量中心, 湖北 武汉 430080; 2. 武汉理工大学机电工程学院, 湖北 武汉 430070)

**摘要:**针对电磁式电流互感器故障诊断效率低、准确率不高问题,提出一种变分模态分解(VMD)和样本熵相结合的故障诊断方法。将原始故障信号通过 VMD 分解成一系列本征模函数(IMF)并进行优选,计算其样本熵作为新的互感器特征提取对象的特征值,与常见时频域特征指标组合成新的特征向量输入 K 近邻分类器进行训练。Matlab 仿真实验结果表明,该方法中新的特征指标用于低压电流互感器故障诊断是有效可行的,可为电磁式电流互感器故障诊断提供参考。

**关键词:**互感器;故障诊断;变分模态分解;样本熵;K 近邻分类器

DOI:10.19781/j.issn.1673-9140.2021.06.017 中图分类号:TM452 文章编号:1673-9140(2021)06-0144-07

## Fault diagnosis of current transformer based on VMD and sample entropy

TANG Dengping<sup>1</sup>, CAI Wenjia<sup>1</sup>, ZHOU Xiangyu<sup>2</sup>, LI Yunfeng<sup>1</sup>, GUO Zheng<sup>1</sup>, LIU Cencen<sup>1</sup>

(1. Measurement Center of State Grid Hubei Electric Power Co., Ltd., Wuhan 430075, China; 2. School of Mechanical and Electrical Engineering, Wuhan University of Technology, Wuhan 430075, China)

**Abstract:** Aiming at the problems of low efficiency and low accuracy of fault diagnosis of electromagnetic current transformers, a fault diagnosis method based on variational mode decomposition (VMD) and sample entropy is proposed. The original fault signal is decomposed into an Intrinsic Mode Function (IMF) series through VMD and optimized. The sample entropy is calculated as the feature value of the new transformer feature extraction object, which is combined with the common time-frequency domain feature index to input the K-nearest neighbor classifier for training. Matlab simulation experiments show that the new characteristic index of this method is effective and feasible for fault diagnosis of low-voltage current transformers, which can provide a reference for fault diagnosis of the electromagnetic current transformer.

**Key words:** current transformer; fault diagnosis; VMD; sample entropy; K-nearest neighbor classifier

低压电动机具有价格便宜、安装方便、体积小巧等优势,各种场合中应用的十分广泛。电流互感器

作为其中重要的一环,其作用是将高压大电流转换为低压小电流,能够很好地应用于检测和保护关

键元器件的场合,不仅提高了工作效率,大幅度降低了成本<sup>[1]</sup>,而且对操作人员和机械设备的安全提供了基本保障。在实际工业生产加工中,互感器稳定的持续工作对低压电动机的安全性和性能起着决定性的影响,因此,为了减少互感器故障造成的不必要的工业生产损失,对于互感器故障的识别监测显得尤为必要<sup>[2]</sup>。

在数据采集过程中,受到采集设备的限制和环境因素的干扰,可能会掩盖采集信号中的故障信息,使故障难以识别。因此,需要对原始故障信号进行分解,以变分模态分解(variational mode decomposition, VMD)<sup>[3]</sup>为代表的自适应准正交分解方法,可以得到包含丰富故障信息的模态信号,达到检测互感器故障的目的。

相比于传统的信号分解算法,如经验模态分解(empirical mode decomposition, EMD)、局部均值分解(local mean decomposition, LMD),VMD 有着更好的噪声鲁棒性<sup>[4]</sup>和计算效率,并且克服了传统方法端点效应和模态混叠等现象<sup>[5-6]</sup>,其在故障诊断领域的运用也愈加广泛。1948 年,由香农提出的信息熵使信息度量开始有了一个参考标准,在此基础上,海内外学者陆续提出近似熵、样本熵等,对时间序列的复杂程度进行量化,从而找到信号特征提取的新方法。

该文选择样本熵作为时间序列复杂程度的量化特征,样本熵具有不依赖于时间序列数据长度的特点,针对非线性非平稳信号的处理表现出相对一致性的优势<sup>[7]</sup>。针对故障发生时的仿真模拟信号提取其特征值,结合常用时频域指标,输入  $K$  近邻分类器进行分类。通过实验表明,所提出的 VMD 和样

本熵相结合的方法能够提高故障诊断结果的准确性与高效性。

## 1 电磁式电流互感器基本原理及故障数学模型

电磁式电流互感器的主要结构包括:一次绕组、二次绕组、铁芯、框架和壳体。设  $N_1$  为一次绕组匝数,串联在电源线路中, $N_2$  为二次绕组匝数,匝数都偏大<sup>[8]</sup>。电磁感应工作原理:在二次绕组上产生逐渐减小的二次电流,二次绕组与二次回路上的设备等负荷串联形成闭合回路。

由电磁感应工作原理可知,电流互感器的工作性能取决于整体的配合状态,其中任一部分出现故障都会造成影响,使误差逐渐增大直至完全失效,从而降低生产能效。突变型和渐变型故障是电流互感器在实际工作中出现最多的 2 种故障类型,其中,突变型故障又分为固定偏差、变比偏差、完全失效 3 种典型故障;渐变式故障主要指漂移偏差故障。

电磁式互感器测量误差由两部分组成:①上述可能故障类型;②测量环境的干扰和测量本身造成的系统误差。对应的数学模型<sup>[9]</sup>为

$$y_t = kx_t + v_x + f_t \quad (1)$$

式中  $y_t$  为互感器测量某一时刻的测量值; $k$  为互感器变比; $x_t$  为某一时刻的真实值; $f_t$  为系统误差; $v_x$  为测量的误差。

在不同故障情形下,系统误差  $f_t$  所对应的数学模型各不相同,如表 1 所示。在不同故障类型中,完全失效故障特点较为明显,可以人为检测,直接判断。

表 1 不同故障类型下的测量数学模型

Table 1 Mathematical model of measurement under different fault types

故障类型	故障描述	故障函数	数学模型
固定偏差	测量值与真实值之间相差某一恒定数值的故障类型	$f_t = b, b$ 为常数	$y_t = kx_t + v_x + b$
变比偏差	互感器因为工作环境的影响或者自身出现故障,变比发生突变,导致互感器的输出信号随之发生变化	$f_t = k_0 x_t, k_0$ 为等效故障变比	$y_t = kx_t + v_x + k_0 x_t$
漂移偏差	长期工作后互感器性能下降,测量值和真实值的差值出现随着时间增加而发生累积的一类故障	$f_t = d(t - t_s), t$ 为故障后测量的任一时刻, $d$ 为偏差常数, $t_s$ 为故障发生的时刻	$y_t = kx_t + v_x + d(t - t_s)$
完全失效	互感器失去效用,测量值固定为某一定值的情况	$c$ 为常数	$y_t = c$

## 2 基于VMD及样本熵的故障特征提取及诊断方法

### 2.1 变分模态分解原理

VMD是依据每个分解成分有一个限制带宽围绕其中心频率 $\omega$ ,从而把原始信号分解成为一系列稀疏本征模函数的信号分解方法。分解的依据是最小化所有本征模函数的带宽之和,对应约束变分问题公式为

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_k u_k(t) = f \end{cases} \quad (2)$$

式中 $u_k$ 为第 $k$ 个子模态序列分量(intrinsic mode functions, IMF); $\omega_k$ 为第 $k$ 个IMF对应的中心频率; $f$ 为输入的原始信号。

利用二次惩罚因子 $\alpha$ 和拉格朗日乘法算子 $\lambda$ 来解决约束变分问题的最优解问题,即将约束变分问题转换为非约束变分问题:

$$\begin{aligned} & L\{u_k\}, \{\omega_k\}, \lambda = \\ & \alpha \sum_k \left\| \partial_t \left[ \left( \xi(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + (\lambda(t), f(t) - \sum_k u_k(t)) \end{aligned} \quad (3)$$

通过重复使用交替方向乘子法(alternating direction method of multipliers, ADMM)算法,迭代更新 $\{u_k\}, \{\omega_k\}$ ,直到满足迭代终止条件,最终获得 $K$ 个模态函数。

### 2.2 样本熵

针对时间序列复杂程度的衡量,引入样本熵(sample entropy, SE)来进行量化,工作状态不同对应的样本熵也不同<sup>[10]</sup>。通过与近似熵对比,样本熵具有更好的时间序列敏锐性、更低的时间序列长度依赖性,从而计算更加简洁高效<sup>[11]</sup>,同时表现出较好的鲁棒性和抗干扰能力。

对于时间序列 $\{x(i), i=1, 2, \dots, N\}$ ,其样本熵的计算步骤<sup>[12]</sup>如下:

1)构建维数为 $m$ 的一组时间序列向量 $\mathbf{X}(i) =$

$\{x(i), x(i+1), \dots, x(i+m-1)\}$ ,其中, $1 \leq i \leq M-m+1$ ;

2)计算向量 $\mathbf{X}(i)$ 与 $\mathbf{X}(j)$ 之间的最大距离,定义为 $d(i, j) = \max\{|x(i+k-1) - x(j+k-1)|\}$ ,其中, $k=1, 2, \dots, m, 1 \leq i, j \leq M-m+1, i \neq j$ ;

3)给定相似容度 $r$ ,把 $d(i, j) < r$ 的数量记录为 $B_i$ ,计算 $B_i$ 与向量总数 $N-m$ 的比值,记为 $B_i^m(r)$ ,求出 $N-m+1$ 个 $B_i^m(r)$ 的平均值,记为 $B^m(r)$ ,即

$$B^m(r) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} B_i^m(r) \quad (4)$$

4)在维数向量为 $m+1$ 下,重复步骤1~3,类比得到 $B^{m+1}(r)$ ;

5)通过给定的相似容限 $r$ 条件下计算嵌入维度为 $m$ 的样本熵:

$$S_E(m, r) = \lim_{x \rightarrow \infty} \left[ -\ln \frac{B^{m+1}(r)}{B^m(r)} \right] \quad (5)$$

当时间序列 $N$ 为有限值时,对样本熵进行估算:

$$S_E(m, r) = -\ln \frac{B^{m+1}(r)}{B^m(r)} \quad (6)$$

### 2.3 K近邻分类器

K近邻分类器有着代码简单编写、容易实现、无需预训练、准确性高以及对异常值有一定容忍度等优点,主要包括3个步骤:

1)设定近邻点个数 $k$ ;

2)计算测试样本 $x_i$ 和每类训练样本 $x_j$ 的欧氏距离:

$$\begin{aligned} & d(x_i, x_j) = \\ & [(x_{i1} - x_{j1})^2 + (x_{i2} - x_{j2})^2 + \\ & \dots + (x_{ip} - x_{jp})^2]^{\frac{1}{2}} \end{aligned} \quad (7)$$

3)将式(7)计算得到的距离大小进行排序,标记与测试目标距离最近的 $k$ 个训练样本作为近邻点;

4)根据标记 $k$ 邻域的主要类别实现测试对象的分类。

### 2.4 基于VMD和K邻近算法(KNN)的故障诊断方法流程

该文提出的基于VMD和K邻近算法(K-NearestNeighbor, KNN)的互感器故障诊断流程如图1所示。首先,将原始互感器信号随机分成训练

集和测试集两部分样本;然后对每个样本进行 VMD 分解,得到一系列 IMF 分量,通过计算样本熵等特征组成特征向量,输入 KNN 分类器实现故障诊断。

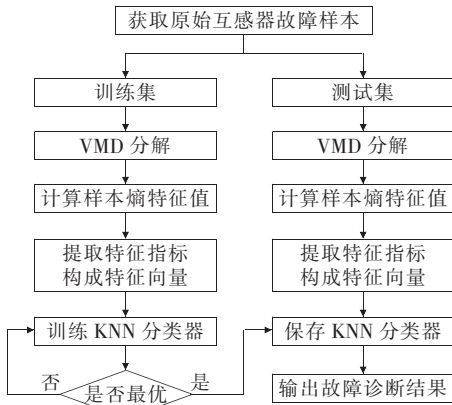


图 1 基于 VMD 与 KNN 的故障诊断方法流程  
Figure 1 The fault diagnosis method based on VMD and KNN

### 3 仿真实验及其结果

#### 3.1 信号仿真及处理

为了证明 VMD 在信号预处理的优势,该文以变比故障信号为例,令  $k=1$ ,变比相对值为 1,采样频率为 4 000 Hz,采集信号时长为 0.2 s,信噪比 (signal-to-noise ratio, SNR) 为 -5。信号图像如图 2 所示,可以发现,有效的故障成分被完全淹没在噪声之中,通过直接使用采集信号对故障进行判断变得十分困难。

设置参数  $k=5, \alpha=10\ 000$ ,利用 VMD 对采集信号进行处理,得到各模态信号如图 3 所示,可以发现, VMD 能够很好地分解信号中的各个组分,使特征提取更加准确。




图 2 原始信号时域

Figure 2 Time-domain diagram of original signal




图 3 VMD 处理各模态信号时域

Figure 3 Time-domain diagram of each modal signal processed by VMD

对采集信号进行 LMD 处理,如图 4 所示,可获得前 3 个 PF 分量;采用集合经验模态分解 (ensemble EMD, EEMD) 对信号进行处理,添加白噪声,振幅为 0.1,集成数为 50,可以得到 9 个 IMF 分量,如图 5 所示;选择与原始信号相关系数最大的前 2 个 IMF 分量 IMF2 和 IMF7 组成重构信号,如图 6 所示。

将 LMD、EEMD 和 VMD 结果与没有添加噪声的模拟信号进行比较,可以发现, LMD 在噪声干扰下,难以实现信号特征的提取成分; EEMD 分解出了故障相关成分,一定程度上抑制了噪声干扰,但计算量较大,没有完全克服噪声干扰,无法满足实际需求; VMD 能够有效地分离各成分,鲁棒性好,计算效率高,对原始信号的故障信息提取以及故障诊断的准确率都有较大幅度的提升。




图 4 LMD 处理信号时域

Figure 4 Time-domain diagram of signal processed by LMD

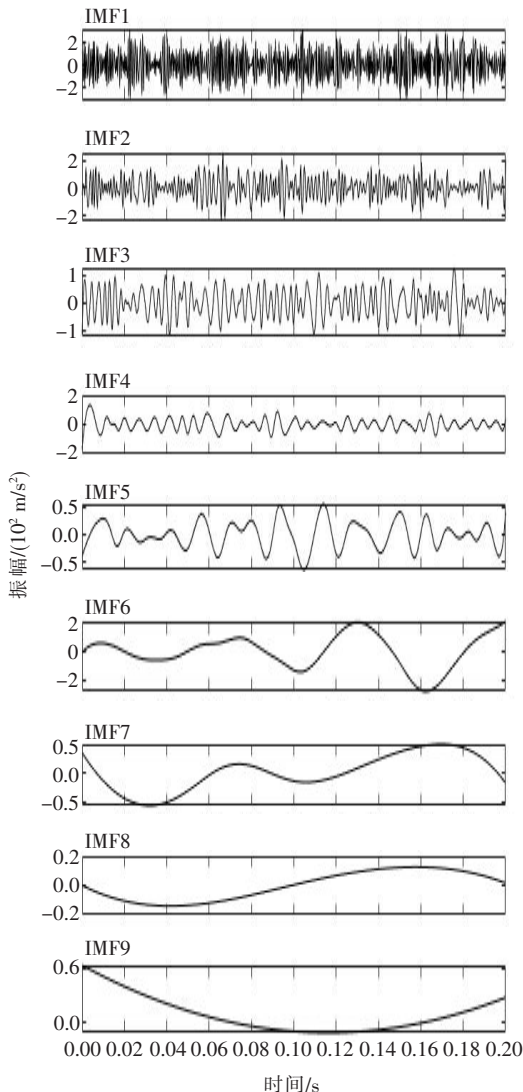


图 5 EEMD 处理信号时域

Figure 5 Time-domain diagram of signal processed by EEMD




图 6 EEMD 重构信号

Figure 6 The reconstruction signal of EEMD

### 3.2 基于 K 近邻算法的故障识别

分别对正常状态和每种故障类型提取 110 组数据样本,通过 VMD 和相关系数准则选择最敏感分量,得到  $4 \times 110$  组数据。然后,每种类型选取其中 20 组数据,构成  $4 \times 20$  组数据作为训练组,选取剩

余 90 组构成  $4 \times 90$  组数据作为测试组,以峰度、均方根、冲击因子等 11 个典型时域特征为代表,结合该文提出的样本熵构成的特征指标,构成 12 维向量特征向量。

输入 K 近邻分类器进行分类,该文选择近邻点个数为 4,样本熵嵌入维度大小为 2,相似容忍度为 0.2,得到故障识别率,如表 2 所示,可以看到,对于互感器单一的故障情况,该文提出的样本熵,能够很好地完成实际故障检测的需求,区别互感器正常状态和各类故障。

表 2 测试数据集结果

Table 2 Test data set results

故障模式	台数	识别台数	正确率/%
固定偏差	90	90	100.0
漂移偏差	90	82	91.1
变比偏差	90	90	100.0
正常状态	90	89	98.9

为了进一步验证该文提出方法不仅在小样本情况下有出色的故障检测能力,而且也拥有出色的稳定性,故重复进行 10 次实验,计算平均值,如表 3 所示,可以看到,对于变比偏差和固定偏差,样本熵依靠其对于时间序列的一致性的优势,能够很好地实现故障检测,对于漂移偏差和正常状态,准确率分别达到 97.6%、96.4%,证明了该文提出方法的有效性。

表 3 该文提出方法重复实验结果

Table 3 Repeat experiment results of the proposed method

实验次数	变比偏差	固定偏差	漂移偏差	正常状态
1	90	90	90	90
2	90	90	89	87
3	90	90	87	87
4	90	90	89	84
5	90	90	88	90
6	90	90	84	87
7	90	90	89	84
8	90	90	90	82
9	90	90	90	88
10	90	90	82	89
平均准确率/%	100	100	97.6	96.4



为了进一步证明该方法的优势,该文分别实验 2 种故障诊断方法作为对照:①基于 VMD、24 组常见时频域指标和 KNN 的故障诊断方法,重复 10 次实验,实验结果如表 4 所示;②基于 EEMD、样本熵和 KNN 故障诊断方法,重复 10 次实验,实验结果如表 5 所示。

表 4 对照组 1 重复实验结果

Table 4 Repeat experiment results of the first control group

实验次数	变比偏差	固定偏差	漂移偏差	正常状态
1	74	69	72	55
2	78	79	70	55
3	72	85	82	45
4	76	81	65	53
5	73	87	62	36
6	79	73	62	57
7	80	73	66	57
8	82	66	63	65
9	85	79	82	59
10	73	85	78	50
平均准确率/%	85.8	86.3	78.0	59.1

表 5 对照组 2 重复实验结果

Table 5 Repeat experiment results of the second control group

实验次数	变比偏差	固定偏差	漂移偏差	正常状态
1	90	90	87	70
2	90	87	76	85
3	90	90	89	68
4	90	89	80	73
5	90	89	83	86
6	90	90	82	63
7	90	90	85	75
8	90	79	83	86
9	90	90	84	69
10	90	89	78	79
平均准确率/%	100	98.1	91.9	83.8

结果表明,常用的 24 组时频域指标难以满足互感器故障诊断任务的需求,准确率远低于该文提出以样本熵作为特征指标的方法;EEMD 结合样本熵对于变比偏差有一定的识别能力,相较于传统时频域指标有一定提升,但对于区分正常状态能力较差,识别准确稳定性较差,难以满足实际故障诊断需求。

综上所述,基于 VMD、样本熵和 KNN 的故障诊断方法针对电流互感器故障诊断具有一定的优势,能够作为一种有效的故障诊断参考方法。

## 4 结语

1)电磁式互感器作为电力装置被大量运用。该文简述互感器的结构原理,分析常见故障类型,针对不同故障类别提出了对应的数学模型并进行仿真。

2)引入样本熵作为电磁式互感器故障的特征指标,利用样本熵对于时间序列长度不敏感、鲁棒性好的优势,进行互感器故障信号的特征提取,相较于传统时频域故障特征的提取,样本熵有着显著优势。

3)该文提出基于 VMD 和样本熵的  $K$  近邻分类器方法,得到较高的诊断准确率,证明了方法的有效性,结合 2 组对比实验结果,进一步证明了该文提出方法的优越性,为互感器故障诊断提供了一个参考思路。

## 参考文献:

- [1] 李敏,靳绍平,胡琛,等. 高压电流互感器泄漏电流测量及消除方法研究[J]. 电力系统保护与控制, 2020, 48(3):156-163.  
LI Min, JIN Shaoping, HU Chen, et al. Research on leakage current measurement and elimination method of high voltage current transformer[J]. Power System Protection and Control, 2020, 48(3):156-163.
- [2] 王昕,尤泽樟,代婷荣,等. 基于 PCA-ELM 算法的电能计量互感器故障诊断[J]. 高压电器, 2019, 55(10):182-188.  
WANG Xin, YOU Zezhang, DAI Tingrong, et al. Fault diagnosis of transformer in electric energy metering system based on PCA-ELM[J]. High Voltage Apparatus, 2019, 55(10):182-188.
- [3] 钱文晓,靳俊杰,司磊,等. 光纤电流互感器故障诊断方法研究综述[J]. 高压电器, 2020, 56(8):43-51.  
QIAN Wenxiao, JIN Junjie, SI Lei, et al. Review of fault diagnosis methods for fiber optical current transformer [J]. High Voltage Apparatus, 2020, 56(8):43-51.
- [4] 姜万录,王浩楠,朱勇,等. 变分模态分解消噪与核模糊 C 均值聚类相结合的滚动轴承故障识别方法[J]. 中国机械工程, 2017, 28(10):1215-1220+1226.

- JIANG Wanlu, WANG Haonan, ZHU Yong, et al. Integrated VMD denoising and KFCM clustering fault identification method of rolling bearings[J]. China Mechanical Engineering, 2017, 28(10): 1215-1220+1226.
- [5] 李晓辉, 李磊, 邹琪, 等. 抗直流电流互感器校验仪检定方法研究[J]. 电测与仪表, 2019, 56(22): 131-138.
- LI Xiaohui, LI Lei, ZOU Qi, et al. Research on verification method of anti DC current transformer calibrator [J]. Electrical Measurement & Instrumentation, 2019, 56(22): 131-138.
- [6] 付华, 刘超, 张松, 等. VMD-SWT 联合算法在故障行波检测中的应用[J]. 电力系统及其自动化学报, 2020, 32(5): 55-61.
- FU Hua, LIU Chao, ZHANG Song, et al. Application of VMD-SWT joint algorithm in fault traveling wave detection[J]. Proceedings of the CSU-EPSA, 2020, 32(5): 55-61.
- [7] 辛忠良, 霍明霞, 贾鹏举, 等. 基于经验小波变换和相关向量机的断路器机械故障诊断[J]. 电测与仪表, 2019, 56(13): 97-103.
- XIN Zhongliang, HUO Mingxia, JIA Pengju, et al. Circuitbreaker mechanical fault diagnosis based on empirical wavelet transform and relevance vector machine[J]. Electrical Measurement & Instrumentation, 2019, 56(13): 97-103.
- [8] 陈建伟, 商玲玲, 裴善鹏, 等. 低压变压器中性点零序电流互感器参数选择[J]. 电工技术, 2018(10): 31-32.
- CHEN Jianwei, SHANG Lingling, PEI Shanpeng, et al. Parameter selection of zero sequence current transformer for neutral point of low voltage transformer[J]. Electrician Technology, 2018(10): 31-32.
- [9] 肖桂雨, 向健平, 凌永志, 等. 基于小波神经网络的风力发电机故障预测方法[J]. 电力科学与技术学报, 2019, 34(2): 195-202.
- XIAO Guiyu, XIANG Jianping, LING Yongzhi, et al. Prediction of wind turbine faults based on wavelet neural networks[J]. Journal of Electric Power Science and Technology, 2019, 34(2): 195-202.
- [10] Cheng G, Chen X, Li H, et al. Study on planetary gear fault diagnosis based on entropy feature fusion of ensemble empirical mode decomposition [J]. Measurement, 2016, 91: 140-154.
- [11] 陈明, 马宏忠, 徐艳, 等. 基于改进掩膜信号优化的经验模态分解算法的有载分接开关机械故障诊断[J]. 智慧电力, 2019, 47(6): 88-94.
- CHEN Ming, MA Hongzhong, XU Yan, et al. Mechanical fault diagnosis of on-load tap changer based on empirical mode decomposition algorithm for improved mask signal[J]. Smart Power, 2019, 47(6): 88-94.
- [12] 谢国民, 黄睿灵, 丁会巧. 基于 VMD 样本熵和 KELM 的输电线路故障诊断[J]. 电子测量与仪器学报, 2019, 33(5): 73-79.
- XIE Guomin, HUANG Ruiling, DING Huiqiao. Fault diagnosis of transmission lines based on VMD sample entropy and KELM[J]. Journal of Electronic Measurement and Instrument, 2019, 33(5): 73-79.