

基于 tFLO-SVMD-LSSVM 及精细复合多尺度模糊散布熵的隔离开关故障诊断方法

葛轩豪*, 马宏忠, 张驰, 董媛, 徐睿涵, 胡国栋

(河海大学 电气与动力工程学院, 江苏南京 211100)

Fault Diagnosis Method for Isolating Switches Based on tFLO-SVMD-LSSVM and RCMFDE

GE Xuanhao*, MA Hongzhong, ZHANG Chi, DONG Yuan, XU Ruihan, HU Guodong

(College of Electrical and Power Engineering, Hohai University, Nanjing 211100, China)

Abstract: [Objective] Currently, isolating switches have been widely used in power grids, but research on their fault diagnosis remains limited compared to equipment such as transformers and circuit breakers. The accurate identification of fault types in isolating switches through vibration signals during their operation is crucial for the normal operation of power grids and the safety of maintenance personnel. [Methods] This paper proposes an improved frilled lizard optimization (FLO) algorithm by incorporating an adaptive t-distribution perturbation strategy (tFLO). Subsequently, the algorithm is applied to parameter optimization for both sequential variational mode decomposition (SVMD) and least squares support vector machine (LSSVM) to achieve accurate fault identification in isolating switches. Firstly, an adaptive t-distribution perturbation strategy was incorporated to improve the FLO algorithm. The tFLO-SVMD then decomposed experimental data to obtain optimal modal components. Next, the refined composite multiscale fuzzy dispersion entropy (RCMFDE) of the modal components was calculated to obtain a high-dimensional feature matrix. Finally, the tFLO-LSSVM algorithm was used to classify faults in multiple sets of low dimensional feature matrices obtained by reducing the dimensionality of the high-dimensional matrices through kernel principal component analysis (KPCA). [Results] The fault diagnosis method based on tFLO-SVMD-LSSVM-RCMFDE proposed in this

study for a 220 kV high voltage isolating switch achieved an accuracy of 97.92%, demonstrating effective identification of various fault types in isolating switches. [Conclusion] There are problems of slow computation speed and poor robustness of modal centers in the intrinsic mode function (IMF) components decomposed by traditional VMD methods, necessitating additional optimization of the number of modes k . The SVMD algorithm can effectively address these issues while achieving more detailed decomposition. Additionally, entropy calculation can effectively quantify the complexity and uncertainty of time series, and fuzzy dispersion entropy (FDE) has the advantages of short computation time and strong anti-interference. Compared to FDE, RCMFDE demonstrates better stability and more comprehensive feature representation. The combination of tFLO-SVMD and RCMFDE can effectively distinguish vibration signals of different fault types. In summary, this study proves that the classification method based on tFLO-SVMD-LSSVM-RCMFDE can effectively identify faults in isolating switches with high accuracy.

Key words: isolating switch; sequential variational mode decomposition; frilled lizard optimization algorithm; adaptive t-distribution perturbation strategy; fuzzy dispersion entropy; kernel principal component analysis; least squares support vector machine; fault diagnosis

摘要:【目的】目前，隔离开关已被广泛应用于电网中，然而对其故障诊断的研究相比于变压器、断路器等设备却较少。通过隔离开关运行时的振动信号来准确识别其故障类型对于电网的正常运行和工作人员的人身安全具有重要意义。【方法】本文采用了自适应 t 分布扰动策略来改进伞蜥优化(FLO)算法，得到改进后的融合自适应 t 分布扰动的伞蜥优化(tFLO)算法，进而对连续变分模态

基金项目: 国家自然科学基金项目(51577050); 国网江苏省电力有限公司重点科技项目(J2024047)

National Natural Science Foundation of China (51577050); State Grid Jiangsu Electric Power Company Key Science and Technology Project (J2024047)

分解(SVMD)和最小二乘支持向量机(LSSVM)的参数寻优,以实现对隔离开关故障的识别。首先,引入自适应 t 分布扰动策略改进 FLO 算法;然后,利用 tFLO-SVMD 对试验数据进行分解得到最佳的模态分量;计算模态分量的精细复合多尺度模糊散布熵(RCMFDE)得到高维特征矩阵;最后,使用 tFLO-LSSVM 算法将核主成分分析法(KPCA)对高维矩阵降维后的多组低维特征值矩阵进行故障的分类。【结果】本文针对某 220 kV 高压隔离开关提出的基于 tFLO-SVMD-LSSVM-RCMFDE 的故障诊断方法的试验准确率达 97.92%,能有效识别隔离开关故障类型。【结论】在传统 VMD 方法分解的本征模态函数(IMF)分量中存在计算速度慢、模态中心鲁棒性差及需要额外优化模态个数 k 等问题,SVMD 算法能够很好地解决这些问题且分解地更细致。同时,熵值计算能有效量化时间序列的复杂性和不确定性,模糊散布熵(FDE)具有计算时间短,抗干扰强的优点。而 RCMFDE 相比于 FDE 稳定性更好,对特征地反映更加全面。tFLO-SVMD 与 RCMFDE 结合能够有效地区分隔离开关不同类型故障的振动信号。综上,本文证明基于 tFLO-SVMD-LSSVM-RCMFDE 分类方法能有效识别隔离开关故障,具有较高的识别精度。

关键词:隔离开关;连续变分模态分解;伞蜥优化算法;自适应 t 分布扰动策略;模糊散布熵;核主成分分析;最小二乘支持向量机;故障诊断

0 引言

高压隔离开关在户外容易受到恶劣自然天气的影响导致非正常运行,不但会影响运维人员的安全,还会对电网的安全运行构成巨大威胁,容易引发重大事故^[1]。因此,在线监测隔离开关的运行状况对检修人员及时发现隔离开关存在的故障隐患、提高隔离开关运行时的可靠性具有重要的指导意义^[2]。

由于隔离开关会进行分合闸操作,在触头与触指碰触时会产生机构的振动,文献[3]表明可以通过分析隔离开关的振动信号来判别隔离开关的故障。文献[4]提出利用经验模态分解(Empirical Mode Decomposition, EMD)算法确定振动信号的特征量,但是 EMD 的端点效应与模态混叠问题比较突出。因此,文献[5]提出用变分模态分解(Variational Mode Decomposition, VMD)法对隔离开关振动信号进行特征提取,引入了正则化项和变分优化,成功抑制了 EMD 中的模态混叠

问题。但是 VMD 仍然需要确定本征模态函数(Intrinsic Mode Function, IMF)分量个数 k 和惩罚因子 γ ,当信号中可分解模态数量较大时,计算成本将大大提高。钟先友^[6]等在 2020 年提出的连续变分模态分解(Sequential Variational Mode Decomposition, SVMD)算法只需人为指定一个平衡参数 α ,有效地提高了收敛速度,并且不会提取不需要的模态,大大减少了计算时间。同样,若随意选取 α ,则存在较大主观性和盲目性的不足,面对不同信号时不能发挥出最大性能^[7]。因此针对此参数优化问题,本文引入了融合自适应 t 分布扰动的伞蜥优化(Frilled Lizard Optimization, FLO)算法对参数进行优化,实现更好的分解效果。

为了反应振动信号的复杂特性、获取更多的特征信息,采用精细复合多尺度模糊散布熵^[8](Refined Composite Multiscale Fuzzy Dispersion Entropy, RCMFDE)计算所有 IMF 的熵值。经特征提取之后得到的熵值具有多尺度性,即得到的熵值为一组高维的特征矩阵,本文采用核主成分分析(Kernel Principal Component Analysis, KPCA)对特征矩阵进行降维操作,使得到的特征空间中的数据点能够更容易地被处理和分析。

故障识别方法包括反向传播(Back Propagation, BP)神经网络、极限学习机(Extreme Learning Machine, ELM)和支持向量机(Support Vector Machine, SVM)等^[9-11]。BP 神经网络故障识别模型存在学习成本高、数据噪声大时容易过拟合等缺点^[12]; ELM 则存在随机初始化输入权值、过拟合等问题^[13-14]; SVM 在参数选取方面较为繁杂,计算速度偏慢^[15]。因此,旨在加快 SVM 的计算速度, Samui P^[16]等提出了最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM),即引入最小二乘法简化 SVM 的求解过程,提高了 SVM 的计算速度。但是 LSSVM 的惩罚因子 C 与核参数 α 同样对其识别性能影响较大,人为选取参数主观性较强。文献[17]采用蜣螂优化算法对 LSSVM 进行改进,对高压断路器进行故障识别,可以证明 LSSVM 在电气设备故障检测方面的可行性。因此本文继续采用 tFLO 算法优化 LSSVM。

综上所述,本文先用 tFLO-SVMD 处理隔离开关振动故障信号,将得到的模态分量提取

RCMFDE 的高维特征矩阵后用 KPCA^[18]降维, 然后把降维后的低维特征矩阵输入到 tFLO-LSSVM 模型中进行分类识别。最后, 经现场试验数据验证所提 tFLO-SVMD-LSSVM-RCMFDE 方法的诊断效果具有优越性。

1 振动信号预处理

1.1 SVMD 理论

SVMD 的特点在于对信号连续应用变分模态提取, 同时添加一些约束以避免收敛到先前提取完成的模态。

把输入信号 $f(t)$ 分解为两个信号:

$$f(t) = u_L(t) + f_r(t) \quad (1)$$

$$f_r(t) = \sum_{a=1}^{L-1} u_a(t) + f_u(t) \quad (2)$$

式中: $u_L(t)$ 为 L 模态的分量; $f_r(t)$ 为残差信号, t 为时刻。

$f_r(t)$ 是除 $u_L(t)$ 以外的输入信号, 包含已经获得的模态 $\sum_{a=1}^{L-1} u_a(t)$ 和信号未处理的部分 $f_u(t)$ 。

为了找到第一模态, $f_r(t)$ 的第一部分为 0, SVMD 的迭代可通过式(3)得到:

$$\hat{u}_L^{n+1}(\omega) = \frac{\hat{f}(\omega) + \alpha^2(\omega - \omega_L^n)^4 \hat{u}_L^n(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{[1 + \alpha^2(\omega - \omega_L^n)^4] \phi} \quad (3)$$

$$\phi = 1 + 2\alpha(\omega - \omega_L^n)^2 + \sum_{a=1}^{L-1} \frac{1}{\alpha^2(\omega - \omega_a)^4} \quad (4)$$

式中: ω 为频率; ω_L 为第 L 个模态的中心频率; $\hat{\lambda}(\cdot)$ 为拉格朗日函数; α 为数据保真度约束的平衡参数, $\alpha \in [0, L]$; $n, n+1$ 为迭代的过程。

拉格朗日乘数 λ 的迭代更新通过双上升法来实现, 如式(5)所示:

$$\begin{aligned} \hat{\lambda}^{n+1} &= \hat{\lambda}^n + \tau \left\{ \hat{f}(\omega) - \right. \\ &\quad \left. [\hat{u}_L^{n+1}(\omega) + \alpha^2(\omega - \omega_L^{n+1})^4 \xi + \sum_{i=1}^{L-1} u_a^{n+1}(\omega)] \right\} \end{aligned} \quad (5)$$

$$\xi = \frac{\hat{f}(\omega) - \hat{u}_L^{n+1}(\omega) - \sum_{i=1}^{L-1} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + \alpha^2(\omega - \omega_L^{n+1})^4} \quad (6)$$

式中: τ 为更新参数。

SVMD 算法逐个提取模态分量, 直至重构误

差达到阈值。

1.2 FLO 算法

Falahah I A 等在 2024 年提出的 FLO 算法^[19]具有独特的算法结构和新颖的迭代方法, 同时有较强的自适应优化能力, 算法流程如下。

(1) 算法初始化

随机初始化搜索伞蜥个体在搜索空间中的主要位置, 如式(7)所示:

$$\mathbf{X} = \begin{bmatrix} \mathbf{X}_1 \\ \vdots \\ \mathbf{X}_i \\ \vdots \\ \mathbf{X}_N \end{bmatrix}_{N \times g} = \begin{bmatrix} x_{1,1} & \cdots & x_{1,s} & \cdots & x_{1,g} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ x_{i,1} & \cdots & x_{i,s} & \cdots & x_{i,g} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ x_{N,1} & \cdots & x_{N,s} & \cdots & x_{N,g} \end{bmatrix}_{N \times g} \quad (7)$$

$$\begin{aligned} x_{i,s} &= lb_s + r_{i,s} \cdot (ub_s - lb_s), i = 1, \dots, N, \\ s &= 1, \dots, m \end{aligned} \quad (8)$$

式中: \mathbf{X} 为 FLO 算法的群体矩阵; \mathbf{X}_i 为第 i 个伞蜥; $x_{i,s}$ 为 FLO 算法在搜索空间中的第 s 个维度; N 为伞蜥的数量; g 为决策变量的数量; r 为区间 $[0, 1]$ 中的随机数; lb_s, ub_s 分别为第 s 个决策变量的下限、上限。

(2) FLO 算法的数学模型

(a) 全局搜索阶段

在 FLO 算法的第一阶段, 使用式(9)确定每只伞蜥的候选猎物位置集:

$$\begin{aligned} CP_i &= \{X_k : F_k < F_i \text{ and } k \neq i\}, \\ \text{where } i &= 1, 2, \dots, N \text{ and } k \in \{1, 2, \dots, N\} \end{aligned} \quad (9)$$

式中: CP_i 为第 i 个伞蜥的候选猎物集合; X_k 为目标函数值比第 i 个伞蜥更好的种群成员; F_k 为 FLO 算法的目标函数值。

在 FLO 算法设计中, 假设伞蜥随机选择其中一个候选猎物并攻击, 使用式(10)计算出种群中每个个体的新位置。如果目标函数值更优, 则用式(10)计算出的新位置替换相应个体的先前位置, 如式(11)所示:

$$x_{i,d}^{P_1} = x_{i,d} + r \cdot (SP_{i,d} - I \cdot x_{i,d}), \quad d = 1, 2, \dots, m \quad (10)$$

$$X_i = \begin{cases} X_i^{P_1}, & F_i^{P_1} < F_i \\ X_i, & \text{else} \end{cases} \quad (11)$$

式中: $X_i^{P_1}$ 为基于 FLO 算法第一阶段对第 i 个伞蜥的新建议位置; $x_{i,d}^{P_1}$ 为伞蜥在第 d 维; $F_i^{P_1}$ 为第一阶段的目标函数值; $x_{i,d}$ 为第 i 个伞蜥的个体位置; r 为区间 $[0, 1]$ 中正态分布的随机数; $SP_{i,d}$ 为第 i 个伞蜥所选猎物的第 d 维, 是从集合 $\{1, 2\}$ 中随机抽取的数字; N 为伞蜥的数量; m 为给出决策变量的数量。

(b) 局部搜索阶段

在 FLO 算法的第二阶段, 使用式(12)计算每个种群个体的新位置。如果该新位置提高了目标函数值, 则使用式(13)替换相应个体的先前位置:

$$x_{i,d}^{P_2} = x_{i,d} + (1 - 2r) \cdot \frac{(ub_d - lb_d)}{t}, \quad t = 1, 2, \dots, T \quad (12)$$

$$X_i = \begin{cases} X_i^{P_2}, & F_i^{P_2} < F_i \\ X_i, & \text{else} \end{cases} \quad (13)$$

$$x(i+1) = \begin{cases} \cos\{\pi\{2rx(i) + 4(1-r)x(i)[1-x(i)] - 0.5\}\}, & x(i) < 0.5 \\ \cos\{\pi\{2r[1-x(i)] + 4(1-r)x(i)[1-x(i)] - 0.5\}\}, & \text{else} \end{cases} \quad (14)$$

式中: $x(i)$ 为第 i 次映射时伞蜥位置的取值。

(2) 引入自适应 t 分布扰动策略。自适应 t 分布扰动策略综合了柯西分布和高斯分布的优点^[22], 本文使用 T 作为 t 分布扰动的自由度参数^[23], 来对 FLO 算法中的伞蜥位置进行扰动, 使算法在迭代前期具有较好的全局搜索能力, 在迭代后期具有良好的局部搜索能力, 并提高算法的收敛速度。具体的位置更新如式(15)所示:

$$x_{i,d}^p = x_{i,d} + t_{\text{distrub}}(T) \cdot x_{i,d} \quad (15)$$

式中: $x_{i,d}^p$ 为变异后的 new 位置; $t_{\text{distrub}}(\cdot)$ 为自适应 t 分布扰动算子。

为了体现 tFLO 算法相较于 FLO 算法以及其他传统优化算法的优势, 选用 CEC2017 函数测试集中对算法性能要求较高的 F1 函数进行测试比较, 结果如图 1 所示。图 1 中, PSO 为粒子群算法 (Particle Swarm Optimization, PSO), BMO 为藤壶优化算法 (Barnacle Mating Optimization, BMO)。

1.4 RCMFDE

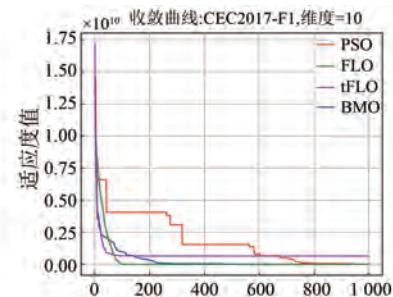
谷学静^[24]等提出了用模糊散布熵 (Fuzzy Dispersion Entropy, FDE) 算法对运动想象脑电信号进行分类识别。但是, 该熵值算法映射步骤中的舍入函数会导致一系列时间序列信息的丢失。而隔离开关的运行环境在户外, 其噪声变化主要

式中: $X_i^{P_2}$ 为基于 FLO 算法第二阶段对第 i 个伞蜥的新建议位置; $x_{i,d}^{P_2}$ 表示伞蜥在第 d 维; $F_i^{P_2}$ 为给出第二阶段的目标函数值; t 为算法的迭代计数器; T 为算法的最大迭代次数。

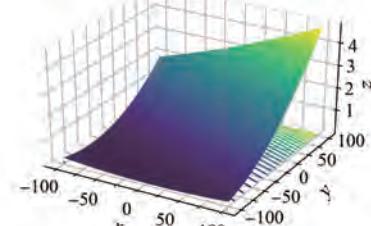
1.3 融合自适应 t 分布扰动策略和改进 FLO 算法

FLO 算法虽然较传统优化算法的寻优能力更强, 但依然存在过早收敛与陷入局部最优等情况。为了避免这类问题, 本文融合混沌映射和自适应 t 分布改进 FLO 算法的搜索能力与优化精度, 主要改进步骤如下。

(1) 将混沌映射应用于伞蜥位置的初始化, 以增加算法的随机性和多样性, 从而加速算法的收敛。本文采用 Tent-Logistic-Cosine 映射^[20]优化伞蜥的初始位置, 如式(14)所示:



(a) tFLO 算法与传统算法收敛性对比
CEC2017-F1



(b) CEC-2017函数三维图

图 1 F1 函数寻优结果图

Fig. 1 Optimization results of F1 function

产生在分合闸瞬间, 所以工程监测的振动数据受附近噪声影响更严重, 计算所得的熵值会受到各种干扰, 影响最终的诊断结果。因此, 本文提出采用 RCMFDE 克服了 FDE 在映射步骤中容易缺失数据的不足, 并且通过多尺度分析能够更全面地

反映信号的特征信息, 提高了计算精度。使用 RCMFDE 对 IMF 分量的处理过程如下。

(1) 对 tFLO-SVMD 算法分解后长度为 L 的 IMF 数据 $h = \{h_1, h_2, \dots, h_L\}$ 等距离划分, 划分的个数定义为 τ , 并定义每一小段数据的起始点。之后, 计算每个分段平均值, 将平均值组合形成粗粒化序列。原始数据 h 及其第 b 个粗粒化序列为

$$f_{b,j}^r = \frac{1}{\tau} \sum_{a=b+\tau(j-1)}^{b+j\tau-1} h_a, \quad 1 \leq j \leq \frac{L}{\tau}, 1 \leq b \leq \tau \quad (16)$$

(2) 计算每个粗粒化散布模式 π 的概率及其平均值。将 $f_{b,j} = \{f_j, j=1, 2, \dots, N\}$ 映射到 $x = \{x_j, j=1, 2, \dots, N\}$ 上。其中, $x_j \in (0, 1)$, 其计算式为

$$x_j = \frac{1}{\sigma \sqrt{2\pi}} \int_{-\infty}^{f_j} e^{-[(t-\mu)^2/(2\sigma^2)]} dt \quad (17)$$

式中: μ 为均值; σ 为标准差。

将 x_j 映射到 $[1, 2, \dots, c]$ 范围内, 得到新的序列 y_j^c :

$$y_j^c = \text{round}(c \cdot x_j + 0.5) \quad (18)$$

式中: c 为时间序列的类数; round 为四舍五入函数。

利用模糊隶属度函数计算 y_j^c 相对于第 q 类的隶属度, 模糊函数为

$$\mu_1(\alpha) = \begin{cases} 0, & \alpha > 2 \\ 2 - \alpha, & 1 \leq \alpha \leq 2 \\ 1, & \alpha < 1 \end{cases} \quad (19)$$

$$\mu_q(\alpha) = \begin{cases} 0, & \alpha < q + 1 \\ q + 1 - \alpha, & q \leq \alpha \leq q + 1 \\ \alpha - q + 1, & q - 1 \leq \alpha \leq q \\ 0, & \alpha < q - 1 \end{cases} \quad (20)$$

$$\mu_c(\alpha) = \begin{cases} 1, & \alpha > c \\ \alpha - c + 1, & c - 1 \leq \alpha \leq c \\ 0, & \alpha < c - 1 \end{cases} \quad (21)$$

式中: q 为 $[1, 2, \dots, c]$ 中的整数; $\mu(\cdot)$ 为关于 y_j^c 的隶属度函数, 用 α 作为自变量代表 y_j^c 。

由嵌入维数 m 和时间延迟 d 构成嵌入向量序列 $\mathbf{y}_w^{m,c}$, 计算式为

$$\mathbf{y}_w^{m,c} = \{\mathbf{y}_w^c, \mathbf{y}_{w+d}^c, \dots, \mathbf{y}_{w+(m-1)d}^c\} \quad (22)$$

式中: $w = 1, 2, \dots, N - (m-1)d$ 。

计算散布模式 $\pi_{v_0 v_1 \dots v_{m-1}}$ ($v = 1, 2, \dots, c$)。若

$\mathbf{y}_w^c = v_0, \mathbf{y}_{w+d}^c = v_1, \dots, \mathbf{y}_{w+(m-1)d}^c = v_{m-1}$, 则 $\mathbf{y}_w^{m,c}$ 对应的散布模式为 $\pi_{v_0 v_1 \dots v_{m-1}}$, 如式(23)所示:

$$\mu_{\pi_{v_0 v_1 \dots v_{m-1}}}(\mathbf{y}_w^{m,c}) = \prod_{w=0}^{m-1} \mu_{v_w}[\mathbf{y}_{w+(j)d}^c] \quad (23)$$

式中: $\mu_{\pi_{v_0 v_1 \dots v_{m-1}}}(\mathbf{y}_w^{m,c})$ 为 $\mathbf{y}_w^{m,c}$ 对模式 $\pi_{v_0 v_1 \dots v_{m-1}}$ 的隶属度, 等于 $\{\mathbf{y}_w^c, \mathbf{y}_{w+d}^c, \dots, \mathbf{y}_{w+(m-1)d}^c\}$ 对类 $v_0 v_1 \dots v_{m-1}$ 隶属度的乘积。

计算所有粗粒化序列下散布模式 $\pi_{v_0 v_1 \dots v_{m-1}}$ 的概率 $P(\pi_{v_0 v_1 \dots v_{m-1}})$, 即:

$$P(\pi_{v_0 v_1 \dots v_{m-1}}) = \frac{\sum_{i=1}^{N-(m-1)d} \mu_{\pi_{v_0 v_1 \dots v_{m-1}}}(\mathbf{y}_w^{m,c})}{N - (m-1)d} \quad (24)$$

(3) 计算 RCMFDE, 如式(25)所示:

$$\begin{aligned} RCMFDE(X, m, c, d, \tau) = \\ - \sum_{n=1}^{c^m} \bar{P}(\pi_{v_0 v_1 \dots v_{m-1}}) \ln \bar{P}(\pi_{v_0 v_1 \dots v_{m-1}}) \end{aligned} \quad (25)$$

式中: $\bar{P}(\pi_{v_0 v_1 \dots v_{m-1}}) = \frac{1}{\tau} \sum_1^\tau P_b^r$ 为粗粒化序列 f_b^r 的散布模式 π 概率的平均值。

RCMFDE 解决了 FDE 在粗粒化过程中信息容易丢失的问题, 并且稳定性更高, 从而保证了最终隔离开关故障识别结果的可靠性。

2 建立故障诊断模型

2.1 LSSVM 分类器

LSSVM 是 SVM 的一种改进算法, 也需要核函数, 并且满足的原则是结构风险最小化。和 SVM 不同的是, LSSVM 具有等式约束, 能同时满足计算精度并且减小计算量。LSSVM 求解最优化问题的目标函数如式(26)所示:

$$\begin{cases} \min J(\mathbf{w}, b, \zeta) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} C \sum_{i=1}^m \zeta_i^2 \\ \text{s. t. } y_i [\mathbf{w}^T \varphi(x_i) + b] = 1 - \zeta_i^2 \end{cases} \quad (26)$$

式中: x_i 为输入量; y_i 为输出量; φ 为 x_i 在特征空间的非线性映射; \mathbf{w} 为超平面权值向量; b 为偏执因子; ζ_i 为松弛变量; C 为惩罚因子。

引入拉格朗日算子 α_i , 得到拉格朗日函数:

$$\begin{aligned} L(\mathbf{w}, b, \zeta, \alpha) = J(\mathbf{w}, b, \zeta) - \\ \sum_{i=1}^m \alpha_i \{y_i [\mathbf{w}^T \varphi(x_i) + b] - 1 + \zeta_i\} \end{aligned} \quad (27)$$

对式(27)求偏导, 再选用径向基函数(Radial Basis Function, RBF)处理, RBF 的表达式为

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (28)$$

最终得到 LSSVM 分类函数表达式:

$$y(x) = \text{sign}\left[\sum_{i=1}^m \alpha_i y_i K(x, x_i) + b\right] \quad (29)$$

LSSVM 的分类精度与其核参数 σ 和惩罚因子 C 有较大关联, 为提高隔离开关故障诊断的准确率, 应采用优化算法先确定核参数 σ 和惩罚因子 C 的取值。本文继续用 tFLO 算法优化 LSSVM 的惩罚因子 C 和核参数 σ 。

2.2 基于 tFLO-SVMD-LSSVM-RCMFDE 的隔离开关故障诊断模型

本文采用 tFLO-SVMD 算法对一维隔离开关振动信号进行分解, 将得到的 IMF 分量继续提取 RCMFDE 得到特征矩阵, 然后采用 KPCA 将得到的高维矩阵降维后输入到 tFLO-LSSVM 中完成对信号的分类诊断。具体流程如图 2 所示。



图 2 基于 tFLO-SVMD-LSSVM-RCMFDE 的隔离开关故障诊断流程

Fig. 2 Fault diagnosis process of isolating switch based on tFLO-SVMD-LSSVM-RCMFDE

3 试验分析

3.1 试验数据采集

本文搭建某 220 kV 的 GW4 型户外高压隔离开关的振动信号测量平台, 在该隔离开关三相左极支架及 A 相横梁中部排布振动信号测试点以测量一维振动信号用以后续试验。

用型号为 1A212E 的 IEPE 式压电式加速度传感器来进行试验, 其采集仪型号为 DH5922。加速度传感器安装在 A 相左极支架、B 相左极支架、C 相左极支架和 A 相横梁中间 4 个位置, 试验现场布置如图 3 所示。



图 3 试验现场振动信号采集图

Fig. 3 On-site vibration signal measure

结合具体结构和故障发生情况, 进行了正常分合闸、机构松动、机构卡涩和三相不同期 4 种典型运行状态模拟, 设置 3 种故障状态如图 4 所示。图 4(a) 为机构松动缺陷模拟图, 试验中松动 A 相主动极连杆关节螺栓来模拟机构松动故障模; 图 4(b) 为机构卡涩模拟图, 试验中将多个橡胶弹性绳捆绑在传动机构关节部位模拟卡涩故障; 图 4(c) 为三相不同期缺陷模拟图, 试验通过调节交叉连杆的长度, 使得其中一相超前或者滞后于其他相。本次试验设置 B 相滞后于 AC 两相, 用来模拟三相不同期故障。



图 4 故障设置

Fig. 4 Fault settings

试验时采样频率设置为 20 kHz, 每组数据采集 10 s。建立 4 种不同采集位置的数据库, 每个数据库含有 4 种类别的图像, 总共为 800 组样本, 每个运行状态的样本数量为 200。按照 7:3 的比例随机划分训练集和验证集后, 训练集样本数量

为 560, 验证集样本数量为 240。

本文分别截取了 A 相测点正常分合闸、机构松动、机构卡涩和三相不同期 4 种典型信号, 并且

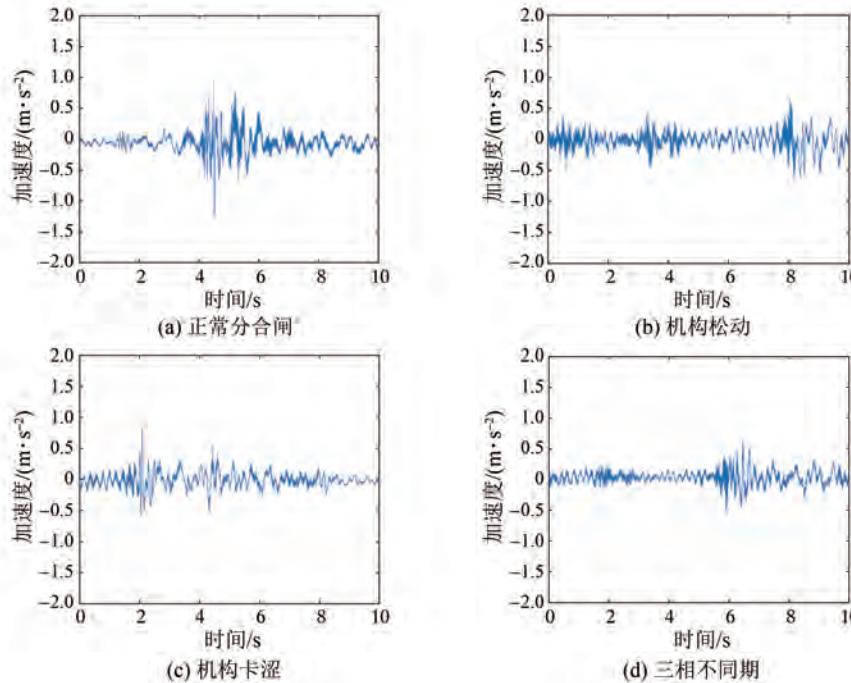


图 5 4 种状态 A 相测点信号

Fig. 5 Signals from phase A measurement points under four states

3.2 试验结果与分析

3.2.1 数据处理

在获取隔离开关 4 种运行状态的振动信号后, 对 tFLO-SVMD 参数进行设置。tFLO 的种群数量设置为 20, 最大迭代次数为 15, 以最小包络熵作为目标函数对平衡参数 α 进行寻优。以机构松动为例, 经过 tFLO-SVMD 寻优后 $\alpha = 15\ 132$, 信号经过 tFLO 优化 VMD 和 SVMD 后结果如图 6 所示。

与 tFLO-SVMD 对比可以发现 tFLO-VMD 需要额外设置并优化模态 k 的数量, 而 SVMD 很好的避免了这个问题, 直接给出了 4 种 IMF 的结果。这种逐次分解的方式可以更好地捕捉到信号中的不同频率成分, 从而加快了算法的运行速度。图 7 为算法的进化曲线对比图, tFLO-SVMD 在迭代到第 2 代时达到收敛, 而未改进的 FLO-SVMD 在第 5 代时达到收敛, PSO-SVMD 则是在第 9 代完成收敛, 并且 tFLO 的寻优效果明显优于其他算法, 因此可以说明本文所提优化方法的优越性。

为证明 RCMFDE 较于 FDE 在信号特征提取

取信号特征最为丰富的 0~5 s 部分, 采样的信号如图 5 所示。

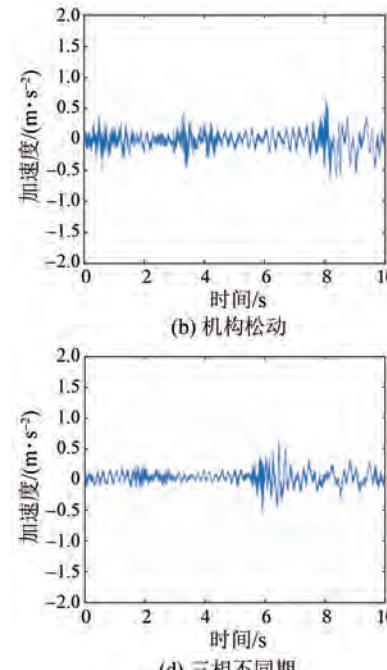


图 5 4 种状态 A 相测点信号

方面的稳定性, 以机构松动和机构卡涩下的振动信号为例, 采用 RCMFDE 和 FDE 计算两组 IMF₁ 信号的熵值。RCMFDE 参数设置为 $m = 3, c = 6, d = 1$, 尺度因子 $\tau = 8$ 。FDE 的熵值如表 1 所示, RCMFDE 熵值曲线如图 8 所示。

表 1 FDE 的值

Tab. 1 FDE values

故障类型	FDE 值
机构松动	$7.031\ 242 \times 10^{-6}$
机构卡涩	$7.421\ 038 \times 10^{-6}$

如图 8 所示, RCMFDE 的熵值曲线整体情况比较平稳, 可以通过多个尺度来衡量 IMF 分量的特征。而单一的 FDE 值明显容易受噪声影响, 对特征反映不够全面。因此本文采用的 RCMFDE 具有更好的特征提取效果, 最终保证了隔离开关故障识别结果的可靠性。

由 RCMFDE 计算得出的特征值矩阵维度为 4×8 (4 种故障类型, 尺度因子 = 8), 其维度较高, 易导致计算结果出现偏差。因此, 本文采用

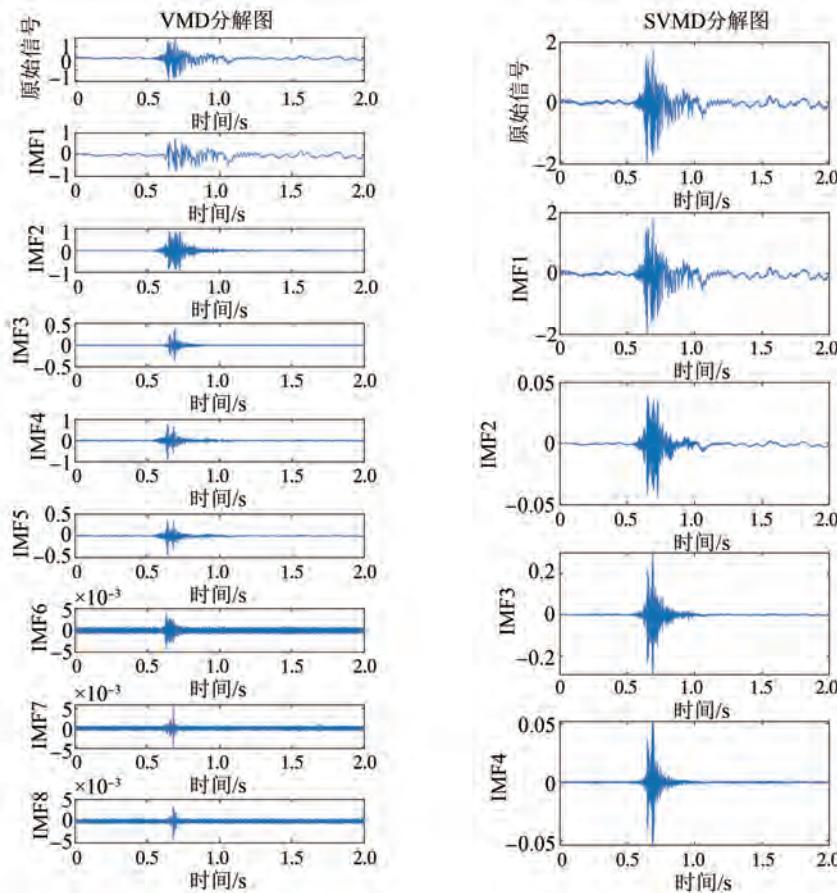


图 6 VMD 和 SVMD 分解图

Fig. 6 Diagrams of VMD and SVMD decomposition

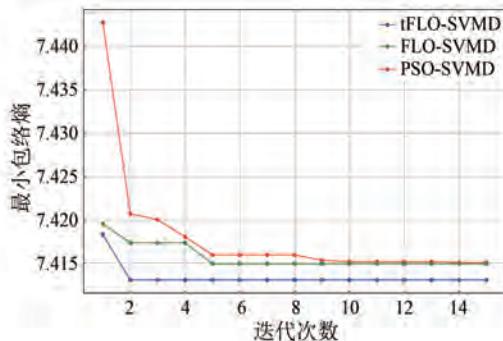


图 7 迭代曲线对比图

Fig. 7 Comparison of iteration curves

KPCA 对特征值矩阵降维。采用 KPCA 计算其贡献率,可以根据贡献率大小选出有用的特征量。图 9 表示随主成分变化的贡献率和累计贡献率。

如图 9 所示,第一主成分的贡献率为 95.97%,该主成分占据了数据的主导信息,因此选择该主成分作为特征向量,其余成分可以放弃。通过 KPCA 降维,由 RCMFDE 计算得到的 4×8 的

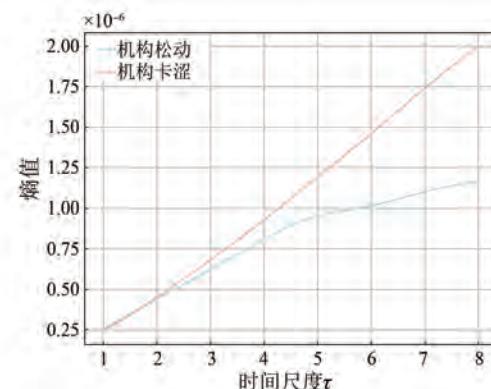


图 8 RCMFDE 熵值曲线图

Fig. 8 RCMFDE entropy curves

特征值矩阵可以简化为 4×1 矩阵。可以看出,KPCA 降维后的矩阵不仅保留了相关性高的特征值,还减少了特征值个数,显著提高了隔离开关故障识别的效率。

3.2.2 评价指标选取

(1) 正确率^[25] (Accuracy): 即所有预测正确的

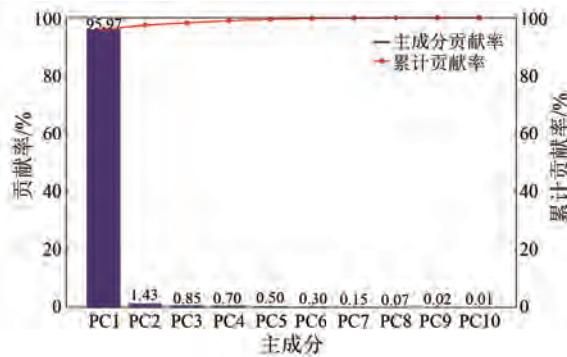


图 9 主成分贡献率及累计贡献率

Fig. 9 Principal component contribution rate and cumulative contribution rate

样本所占的总比重,计算式为

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (30)$$

式中: TP 为预测正确的正样本数量; TN 为预测正确的负样本数量; FP 为预测错误的正样本数量; FN 为预测错误的负样本数量。

(2) 精确率^[26] (Precision): 即真正正确的样本占所有预测为正的比例,计算式为

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (31)$$

(3) 召回率^[27] (Recall): 即真正正确的样本占所有实际为正的比例,计算式为

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (32)$$

(4) 宏平均^[28] (Macro-averaging): 先对每一类单独计算指标值,然后再对所有类求算术平均值,对精确率序列 P_i 和召回率序列 R_i 进行宏平均计算,则

$$\begin{aligned} \text{Macro_P} &= \frac{1}{n} \sum_{i=1}^n P_i \\ \text{Macro_R} &= \frac{1}{n} \sum_{i=1}^n R_i \end{aligned} \quad (33)$$

3.2.3 故障诊断模型的评价

本文采用 LSSVM 算法对 240 组处理后的隔离开关振动数据进行分类识别,其中正常分合闸(标签 0)、机构松动(标签 1)、机构卡涩(标签 2)和三相不同期(标签 3)的数据均为 60 组。为了便于比较,本文使用了 tFLO-SVMD-LSSVM-RCMFDE、tFLO-SVMD-SVM-RCMFDE、tFLO-SVMD-LSSVM-FDE、PSO-SVMD-LSSVM-RCMFDE、EMD-LSSVM-

FDE 与本文的 tFLO-SVMD-LSSVM-RCMFDE 分类算法进行对比,结果如图 10 所示。分类结果正确率如表 2 所示,宏平均精确率和宏平均召回率对比如表 3 所示。

表 2 分类结果正确率对比表
Tab. 2 Comparison of accuracy rates of classification results

算法名称	分类组数 n	正确分类数 m	正确率/%
tFLO-SVMD-LSSVM-RCMFDE	240	235	97.92
tFLO-SVMD-SVM-RCMFDE	240	231	96.25
tFLO-SVMD-LSSVM-FDE	240	227	94.58
PSO-SVMD-LSSVM-RCMFDE	240	222	92.50
EMD-LSSVM-FDE	240	215	89.58

表 3 宏平均精确率和宏平均召回率对比表

Tab. 3 Comparison of macro average precision and recall rates

算法名称	宏平均精确率/%	宏平均召回率/%
tFLO-SVMD-LSSVM-RCMFDE	97.93	97.92
tFLO-SVMD-SVM-RCMFDE	96.65	96.64
tFLO-SVMD-LSSVM-FDE	95.01	94.99
PSO-SVMD-LSSVM-RCMFDE	92.56	92.50
EMD-LSSVM-FDE	89.78	89.58

表 2 显示,使用 FDE 作为特征熵诊断正确率仅为 94.58%,因此,FDE 量化出的特征值矩阵并不能高效识别出正常分合闸、机构松动、机构卡涩和三相不同期这 4 种工况。同理,表 2 证明用 SVM^[29-30]作为分类器、使用 EMD 进行信号分解亦无法达到最优的分类效果。此外,tFLO 算法相对于传统的 PSO 算法的优化效果更显著,愈发体现了 tFLO-SVMD-LSSVM-RCMFDE 算法的优越性。表 3 进一步说明了本文提出算法在精确率和召回率上明显优于其他算法,对于隔离开关故障诊断有着明显的适用性。

综上,本文试验证明基于 tFLO-SVMD-LSSVM-RCMFDE 分类能有效识别隔离开关故障,具有较高的识别精度。

4 结语

本文提出一种基于 tFLO-SVMD-LSSVM-RCMFDE 的隔离开关故障诊断方法。采用 tFLO-

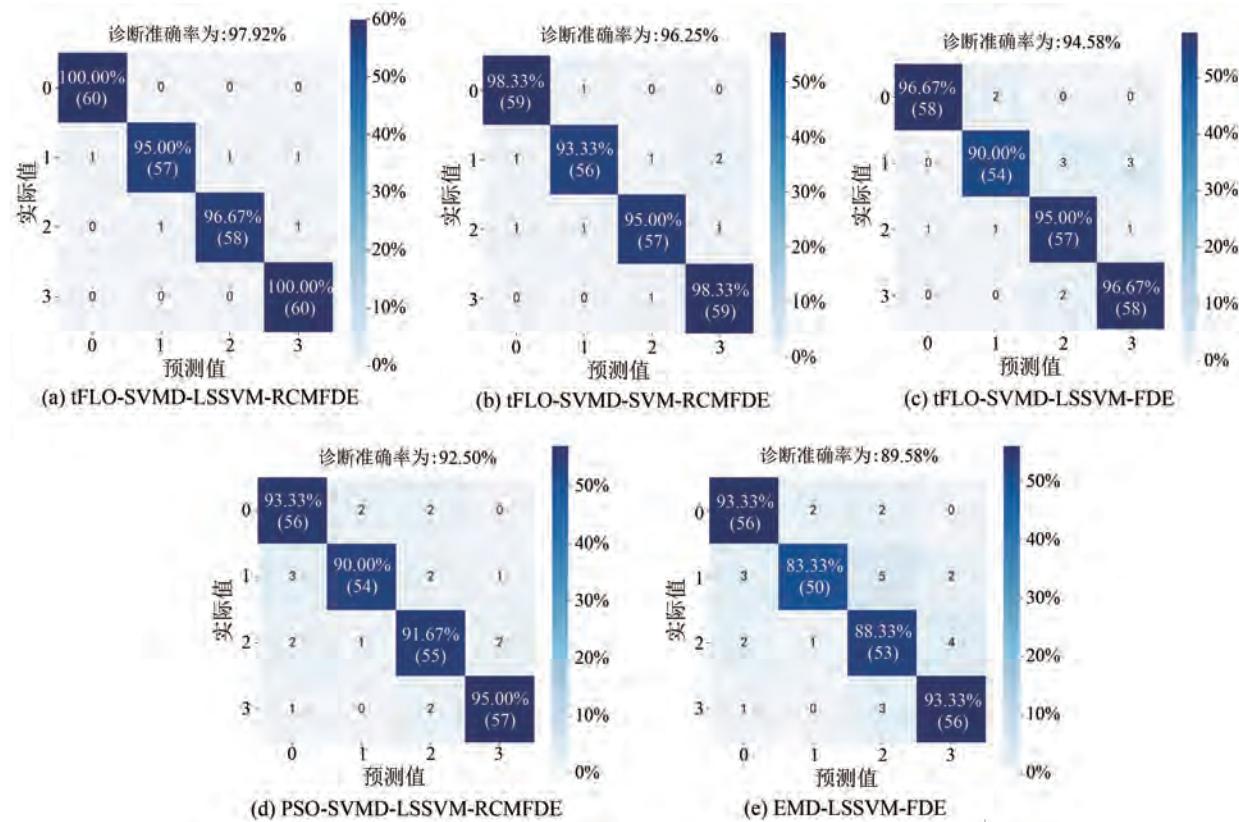


图 10 各算法分类结果图

Fig. 10 Classification results of different algorithms

SVMD 分解隔离开关的振动信号, 利用 RCMFDE 对分解后的特征分量进行量化。其中 RCMFDE 在信号量化方面具有关键的作用。同时本文采用 tFLO-LSSVM 对提取出的特征值进行分类识别, 结论如下。

(1) 传统 VMD 方法分解的 IMF 分量存在计算速度慢、模态中心鲁棒性差以及需要额外优化模态个数 k 的问题。SVMD 算法能够很好地解决该问题, 同时 SVMD 分解地更细致。

(2) 熵值计算能有效量化时间序列的复杂性和不确定性, FDE 具有计算时间短、抗干扰强的优点。而 RCMFDE 相比于 FDE 稳定性更好, 对特征的反映更加全面。tFLO-SVMD-LSSVM-RCMFDE 能够有效地区分隔离开关不同类型故障的振动信号, 准确率达到了 97.92%, 为隔离开关故障分析提供了一种有效的诊断方式。

利益冲突声明

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of

interests.

作者贡献

葛轩豪进行了方案设计、内容总结与论文撰写, 葛轩豪、张驰、董媛、徐睿涵、胡国栋进行了试验研究, 马宏忠、张驰、董媛、徐睿涵、胡国栋参与了论文的审核与修改。所有作者均阅读并同意了最终稿件的提交。

The scheme design, content summary, and paper writing were conducted by Ge Xuanhao. The experiment was conducted by Ge Xuanhao, Zhang Chi, Dong Yuan, Xu Ruihan, and Hu Guodong. The manuscript was reviewed and revised by Ma Hongzhong, Zhang Chi, Dong Yuan, Xu Ruihan, and Hu Guodong. All authors have read and approved the final version of the paper for submission.

参考文献

[1] 田鹏, 崔其会, 张建华, 等. 基于电流-振动信号

- 和 GA-SVM 的隔离开关故障诊断 [J]. 高电压技术, 2023, 49(增刊1): 179-185.
- TIAN P, CUI Q H, ZHANG J H, et al. Fault diagnosis of isolation switches based on current-vibration signals and GA-SVM [J]. High Voltage Engineering, 2023, 49(S1): 179-185.
- [2] 张赛鹏, 冯世涛, 赵春明, 等. 基于威布尔分布和蒙特卡洛法的高压隔离开关可靠性研究 [J]. 高压电器, 2021, 57(6): 86-93+101.
- ZHANG S P, FENG S T, ZHAO C M, et al. Study on reliability of high voltage disconnector based on Weibull distribution and Monte Carlo method [J]. High Voltage Apparatus, 2021, 57(6): 86-93+101.
- [3] 李少华, 张文涛, 宋亚凯, 等. 基于高压隔离开关振动信号的故障诊断方法分析 [J]. 内蒙古电力技术, 2018, 36(1): 89-92.
- LI S H, ZHANG W T, SONG Y K, et al. Analysis of fault diagnosis method based on vibration signal of high-voltage disconnector [J]. Inner Mongolia Electric Power, 2018, 36(1): 89-92.
- [4] 郭煜敬, 陈士刚, 李少华, 等. 基于经验模态分解及支持向量机的高压隔离开关机械故障诊断方法 [J]. 高压电器, 2018, 54(9): 12-18.
- GUO Y J, CHEN S G, LI S H, Mechanical fault diagnosis method of high-voltage disconnector based on empirical modal decomposition and support vector machine [J]. High Voltage Apparatus, 2018, 54(9): 12-18.
- [5] 薛健桐, 马宏忠. 基于 VMD 和 WOA-SVM 的变压器绕组松动故障诊断 [J]. 电机与控制应用, 2023, 50(8): 84-90.
- XUE J T, MA H Z. Fault diagnosis for winding looseness of transformer based on VMD and WOA-SVM [J]. Electric Machines & Control Application, 2023, 50(8): 84-90.
- [6] 钟先友, 何流, 赵潇. 基于 SVMD 与参数优化 MCKD 的轴承故障诊断 [J]. 机电工程, 2024, 41(7): 1179-1188.
- ZHONG X Y, HE L, ZHAO X. Bearing fault diagnosis based on SVMD and parameter optimized MCKD [J]. Mechanical & Electrical Engineering, 2024, 41(7): 1179-1188.
- [7] NAZARI M, SAKHAEI S M. Successive variational mode decomposition [J]. Signal Processing, 2020, 174: 107610.
- [8] 陈演斐, 凌志豪, 李志新, 等. 基于参数优化 VMD 和多尺度模糊熵的星-三角接法 FS-PMM 匝间短路故障诊断方法 [J]. 电机与控制应用, 2024, 51(6): 31-43.
- CHEN Z F, LING Z H, LI Z X, et al. Fault diagnosis of inter-turn short circuit fault in star-delta connection FS-PMM based on parameter optimization VMD and multi-scale fuzzy entropy [J]. Electric Machines & Control Application, 2024, 51(6): 31-43.
- [9] 刘子英, 张婧, 邓芳明. 基于 BP 神经网络的高压隔离开关分合闸监测识别 [J]. 电力系统保护与控制, 2020, 48(5): 134-140.
- LIU Z Y, ZHANG J, DENG F M. Monitoring and identification of state of opening or closing isolation switch based on BP neural network [J]. Power System Protection and Control, 2020, 48(5): 134-140.
- [10] 曾瑞江, 黄缙华, 李志勇. 基于小波包能量谱和 ELM 的光伏逆变器多故障在线诊断 [J]. 电工材料, 2024, (4): 71-74.
- ZENG R J, HUANG J H, LI Z Y. Multi-fault online diagnosis of solar inverter based on wavelet packet energy spectrum and ELM [J]. Electrical Engineering Materials, 2024, (4): 71-74.
- [11] 刘仕兵, 马志方, 仇智圣. 接触网隔离开关机械状态监测的 SVM 实现 [J]. 计算机仿真, 2019, 36(5): 445-449.
- LIU S B, MA Z F, QIU Z S. SVM implementation of mechanical monitoring for disconnector of contact line [J]. Computer Simulation, 2019, 36(5): 445-449.
- [12] 赵文清, 严海, 周震东, 等. 基于残差 BP 神经网络的变压器故障诊断 [J]. 电力自动化设备, 2020, 40(2): 143-148.
- ZHAO W Q, YAN H, ZHOU Z D, et al. Fault diagnosis of transformer based on residual BP neural network [J]. Electric Power Automation Equipment, 2020, 40(2): 143-148.
- [13] 崔星, 陈静, 孙婧琪, 等. 基于 ICEEMDAN 多尺度模糊熵和 MVO-KELM 的变压器绕组铁心机械故障诊断 [J]. 电机与控制应用, 2023, 50(10): 81-90.
- CUI X, CHEN J, SUN J Q, et al. Mechanical fault diagnosis for transformer winding core based on ICEEMDAN multi-scale fuzzy entropy and MVO-KELM [J]. Electric Machines & Control

- Application, 2023, 50(10): 81-90
- [14] 刘钦东, 罗勇水, 张军华, 等. 基于 WPT-SVD-KELM 的大型风力机叶片表面裂纹识别方法研究 [J]. 太阳能学报, 2023, 44(3): 155-161.
- LIU Q D, LUO Y S, ZHANG J H, et al. Research on surface crack identification method of large wind turbine blade based on WPT-SVD-KELM [J]. Acta Energiae Solaris Sinica, 2023, 44(3): 155-161.
- [15] 王浩楠, 崔宝珍, 彭智慧, 等. 应用 ICEEMDAN 和 SVM 的行星齿轮箱故障诊断 [J]. 机械科学与技术, 2023, 42(1): 24-30.
- WANG H N, CUI B Z, PENG Z H, et al. Fault diagnosis of planetary gearbox using ICEEMDAN and SVM [J]. Mechanical Science and Technology for Aerospace Engineering, 2023, 42(1): 24-30.
- [16] SAMUI P, KOTHARI D P. Utilization of a least square support vector machine (LSSVM) for slope stability analysis [J]. Scientia Iranica, 2011, 18(1): 53-58.
- [17] 尤敬尧, 段洁, 伍瑞泽. 基于改进蜣螂算法优化 LSSVM 的断路器故障诊断方法研究 [J]. 红水河, 2024, 43(4): 132-137+144.
- YOU J Y, DUAN J, WU R Z. Fault diagnosis method of circuit-breaker based on LSSVM optimized by improved dung beetle optimizer [J]. Hongshui River, 2024, 43(4): 132-137+144.
- [18] 徐艳, 周建勋, 金鑫, 等. 基于 KPCA-K-means-GRU 的短期风电功率预测研究 [J]. 电机与控制应用, 2023, 50(2): 49-55.
- XU Y, ZHOU J X, JIN X, et al. Study on short-term wind power prediction based on KPCA-K-means-GRU [J]. Electric Machines & Control Application, 2023, 50(2): 49-55.
- [19] FALAHAH I A, AL-BAIK O, ALOMMARI S, et al. Frilled lizard optimization: A novel nature-inspired metaheuristic algorithm for solving optimization problems [J]. Computers, Materials & Continua, 2024, 79(6): 3631-3678.
- [20] HUA Z Y, ZHOU Y C, HUANG H J. Cosine-transform-based chaotic system for image encryption [J]. Information Sciences, 2019, 480: 403-419.
- [21] 胡竟杰, 储昭碧, 郭渝乐, 等. 基于自适应 t 分布与动态权重的樽海鞘群算法 [J]. 计算机应用研究, 2023, 40(7): 2068-2074.
- HU J J, CHU Z B, GUO Y L, et al. Salp swarm algorithm based on adaptive t-distribution and dynamic weight [J]. Application Research of Computers, 2023, 40(7): 2068-2074.
- [22] 刘兴阳, 毛力. 基于 t 分布变异的自适应差分进化算法 [J]. 计算机工程与应用, 2012, 48(2): 127-129.
- LIU X Y, MAO L. Self-adaptive differential evolution algorithm using mutations based on the t distribution [J]. Computer Engineering and Applications, 2012, 48(2): 127-129
- [23] 张伟康, 刘升. 自适应 t 分布与黄金正弦改进的麻雀搜索算法及其应用 [J]. 微电子学与计算机, 2022, 39(3): 17-24.
- ZHANG W K, LIU S. Improved sparrow search algorithm based on adaptive t-distribution and golden sine and its application [J]. Microelectronics & Computer, 2022, 39(3): 17-24
- [24] 谷学静, 杨赵辉, 郭宇承, 等. 基于多维特征融合与多元宇宙优化算法的脑电信号处理 [J]. 中国测试, 2025, 51(3): 131-138.
- GU X J, YANG Z H, GUO Y C, et al. EEG signal processing based on multi-dimensional feature fusion and multi verse optimizer [J]. China Measurement & Testing Technology, 2025, 51(3): 131-138.
- [25] 薛维刚, 谭迎春, 施小刚, 等. 基于时间信息建模和特征融合的多模态藏酋猴行为识别 [J/OL]. 计算机工程与应用, 2025-3-11. <https://link.cnki.net/urlid/11.2127.TP.20250311.1747.002>.
- XUE W G, TAN Y C, SHI X G, et al. Multi-modal behavior recognition of Tibetan macaques based on temporal information modeling and feature fusion [J/OL]. Computer Engineering and Applications, 2025-3-11. <https://link.cnki.net/urlid/11.2127.TP.20250311.1747.002>.
- [26] 申振龙, 童燕翔, 王萧, 等. 基于 BERT 模型的跨链异常交易检测 [J/OL]. 计算机工程, 2025-3-18. <https://link.cnki.net/doi/10.19678/j.issn.1000-3428.0070479>.
- SHEN Z L, TONG Y X, WANG X, et al. Cross-chain anomalous transaction detection based on BERT model [J/OL]. Computer Engineering, 2025-3-18. <https://link.cnki.net/doi/10.19678/j.issn.1000-3428.0070479>.
- [27] 韩小平, 王宁, 张超, 等. 基于改进 YOLOv5n 的多品种蔬菜轻量化识别方法研究 [J/OL]. 南京农业大学学报, 2025-3-14. <https://link.cnki.net/urlid/32.1148.s.20250314.1632.002>.

- HAN X P, WANG N, ZHANG C, et al. Research on lightweight method for multi-variety vegetable recognition based on improved YOLOv5n [J/OL]. Journal of Nanjing Agricultural University, 2025-3-14. <https://link.cnki.net/urlid/32.1148.s.20250314.1632.002>.
- [28] 张大伟, 秘蓉新, 周培姚, 等. 基于大模型的非均衡样本文本分类优化方法[J]. 软件工程, 2025, 28(3):47-50+78.
- ZHANG D W, MI R X, ZHOU P Y, et al. Optimization method for imbalanced text classification based on large models [J]. Software Engineering, 2025, 28(3):47-50+78.
- [29] 袁旭, 龚正朋, 俞文帅, 等. 基于小波包奇异谱熵和 WOA-SVM 的 GIS 放电故障诊断[J]. 电机与控制应用, 2024, 51(9): 60-69.
- ZANG X, GONG Z P, YU W S, et al. GIS discharge fault diagnosis based on wavelet packet singular spectral entropy and WOA-SVM [J]. Electric Machines & Control Application, 2024, 51(9): 60-69.
- 69.
- [30] 刘可真, 姚岳, 赵现平, 等. 基于样本集成学习和 SO-SVM 的变压器故障诊断[J]. 电机与控制应用, 2023, 50(12): 21-31.
- LIU K Z, YAO Y, ZHAO X P, et al. Transformer fault diagnosis based on sample integration learning and SO-SVM [J]. Electric Machines & Control Application, 2023, 50(12): 21-31.

收稿日期:2024-12-31

收到修改稿日期:2025-02-07

作者简介:

葛轩豪(2000-),男,硕士研究生,主要研究方向为电力设备状态监测与故障诊断,1006694841@qq.com;

*通信作者:葛轩豪(2000-),男,硕士研究生,主要研究方向为电力设备状态监测与故障诊断,1006694841@qq.com。