

DOI: 10.19783/j.cnki.pspc.231283

## 基于 ISSA-XGBoost 的电能质量扰动识别方法研究

商立群, 李朝彪, 邓力文, 郝天奇, 刘 晗

(西安科技大学电气与控制工程学院, 陕西 西安 710054)

**摘要:** 针对传统电能质量扰动(power quality disturbances, PQDs)识别中特征提取有冗余, 识别精度不高等问题, 提出了一种基于改进麻雀搜索算法(improved sparrow search algorithm, ISSA)优化特征选择和极致梯度提升(eXtreme gradient boosting, XGBoost)的电能质量扰动识别方法。首先对电能质量扰动信号进行 S 变换, 提取 61 种电能质量特征。再通过 ISSA 同时选择最优特征子集和 XGBoost 中最优参数, 剔除冗余特征, 提高识别精度。最后根据优化后的最优特征子集和 XGBoost 实现电能质量扰动的识别。仿真结果表明, 所提出的方法能有效选择最优特征子集, 对噪声环境下的 19 种电能质量扰动信号进行高效识别, 并且具有较高的识别精度。

**关键词:** 电能质量; 扰动识别; XGBoost; 麻雀搜索算法

### A power quality disturbance identification method based on ISSA-XGBoost

SHANG Liqun, LI Chaobiao, DENG Liwen, HAO Tianqi, LIU Han

(College of Electrical and Control Engineering, Xi'an University of Science and Technology, Xi'an 710054, China)

**Abstract:** To solve the problem of redundancy and low recognition accuracy in traditional power quality disturbance recognition, this paper proposes a method based on an improved sparrow search algorithm (ISSA) to optimize feature selection and eXtreme gradient boosting (XGBoost). First, the power quality disturbance signal is transformed by S-transform, and 61 kinds of power quality characteristics are extracted. Then ISSA selects the optimal feature subset and the optimal parameters in XGBoost at the same time to eliminate redundant features and improve recognition accuracy. Finally, the power quality disturbance is identified according to the optimized feature subset and XGBoost. The simulation results show that the method proposed can effectively select the optimal feature subset, and efficiently identify 19 kinds of power quality disturbance signals in a noisy environment, and has high recognition accuracy.

This work is supported by the Natural Science Basic Research Plan of Shaanxi Province (No. 2021JM393).

**Key words:** power quality; disturbance identification; XGBoost; sparrow search algorithm

## 0 引言

随着电力系统的逐渐发展以及风电、光伏等新能源渗透率的提高, 电网中越来越频繁地发生电能质量扰动事件, 此类事件的发生不利于电力系统安全、经济、高效运行。而新能源并网、电动汽车充电桩、通信领域等所采用的电力电子设备又对电能质量有着极高的要求。因此, 设计一种高效且准确率高的电能质量扰动识别算法是治理电能质量问题的前提, 具有重要的现实意义<sup>[1-4]</sup>。

电能质量扰动(power quality disturbances, PQDs)的识别一般包括 3 个步骤: (1) 采用信号处理技术进行特征提取; (2) 对提取后的特征进行选择; (3) 选择合适的分类器对扰动进行识别。傅里叶变换(fourier transform, FT)、短时傅里叶变换(short time fourier transform, STFT)、小波变换(wavelet transform, WT)、S 变换等信号处理技术被广泛应用在波形的检测和特征提取<sup>[5]</sup>。虽然 FT 经常被用于分析信号的频谱和谐波成分, 但对于非平稳的电能质量扰动并不适用, 且可能会出现错误的结果。文献[6]采用短时傅立叶变换处理信号, 该方法首先对信号进行加窗处理, 再进行傅里叶变换, 弥补了傅里叶变换不能处理非平稳信号的不足; 该方法的缺点是一旦窗

基金项目: 陕西省自然科学基金基础研究计划项目资助 (2021JM393)

宽确定,其分辨率是固定的。文献[7]利用小波变换有效提取 PQDs 的特征,但该方法容易受到残差噪声的影响,且对平稳信号分析不足;S 变换在 STFT 和 WT 基础之上做出改进,采用频率与窗口宽度成反比的高斯窗函数,改善了窗宽固定的缺陷,并且具有一定的噪声抑制能力。文献[8]采用 S 变换对信号处理后的矩阵提取出 9 种扰动时频域特征,并将其输入混沌集成决策树,最终完成 23 种 PQDs 的识别。文献[9]采用 S 变换对信号进行多分辨率分析,得到 PQDs 的不同统计特征;然后采用基于决策树初始化模糊 C 均值聚类方法识别 PQDs,并且在硬件上验证了方法的有效性。

特征选择的目的是寻找解决问题所必须的、足够的、最小的特征子集。文献[10]利用核主成分分析对 15 种特征进行降维,得到的 6 种特征能准确表达变压器故障的有效信息。文献[11]利用不同的模糊邻域半径和变精度系数,构建粒度不同的粒度空间,基于变精度模糊邻域粗糙集(variable precision fuzzy neighborhood rough set, VPFNRS)特征选择算法,在各粒度空间下选择出对应的最优扰动特征子集。文献[12]采用基于交互作用下改进的最大相关-最小冗余准则算法,降低了特征提取手段局限性导致的典型特征边缘模糊对辨识精度的影响。文献[13]采用能量熵和功率谱熵对扰动特征进行组合提取,构建的特征向量具有高精度、低维度的特点。进化计算算法通过模拟自然界生物进化机制完成搜索问题的最优解决方案,近年来在特征选择问题中得到了广泛应用,并取得了一定的成功。文献[14]概述了基于进化计算的特征选择的基本框架,并且从进化计算特征选择方法的搜索机制、子集评价策略等方面进行了分析和总结。文献[15]采用自适应樽海鞘群作为特征选择算法,经过对比,自适应樽海鞘群经过特征选择后的识别准确率最高。文献[16]将分类误差和特征数量共同最小化作为适应度函数,采用非支配排序遗传算法 II(non-dominated sorting genetic algorithm II, NSGA-II)求出不同的帕累托最优解,保证了良好的准确率和更短的计算时间。

人工神经网络(artificial neural network, ANN)、支持向量机(support vector machines, SVM)、决策树(decision tree, DT)、K 近邻(K nearest neighbors, KNN)和极限学习机(extreme learning machine, ELM)等传统的机器学习分类模型可以用来对 PQDs 进行识别。近年来,基于集成学习的方法因其可行性和准确性在非平稳信号分类中获得了广泛的应用。文献[17]采用经验小波变换作为信号处理方法,并提取 12 个特征作为极致梯度提升(eXtreme gradient boosting,

XGBoost)的输入,基于贝叶斯理论对 XGBoost 进行优化,提高二元关联极致梯度提升(binary relevance-XGBoost, BR-XGBoost)模型的精度。文献[18]采用模因萤火虫算法(memetic firefly algorithm, MFA)对轻量级梯度提升(light gradient boost machine, LGBM)中 5 个参数进行优化,提高了识别精度,但文中并没有对特征进行选择,会导致训练时间大大增加。

针对上述问题,本文提出一种基于改进麻雀搜索算法优化特征选择和极致梯度提升的电能质量扰动识别方法。首先通过 S 变换对 19 种 PQDs 进行处理,提取 61 个时频域特征组成扰动特征集。然后采用经动态权重、levy 飞行和自适应贪婪、变异策略改进的麻雀搜索算法优化扰动特征集和 XGBoost 参数,去除冗余特征,提高 XGBoost 的识别精度。最后通过仿真实验和分析,验证了本文所提方法的准确性和有效性。

## 1 电能质量扰动信号数学模型

本文共考虑了 19 种电能质量扰动信号,包括电压暂降、电压暂升、电压中断、电压闪变、暂态振荡、暂态脉冲和谐波 7 种单一电能质量扰动信号和电压暂降+谐波、电压暂升+谐波、电压中断+谐波、电压闪变+谐波及电压暂降+暂态振荡等 12 种复合类型电能质量扰动信号。根据 IEEE-1159 标准<sup>[19]</sup>构建电能质量扰动信号的数学模型,见附录 A 表 A1 所示。

## 2 基于 S 变换的特征提取

S 变换采用时窗宽度随频率成反比的高斯窗作为窗函数,可以在高频段提供更高的时间分辨率,在低频段提供更好的频率分辨率。设输入信号为  $x(t)$ ,其 S 变换后为  $S(\tau, f)$ ,数学表达式如式(1)。

$$\begin{cases} S(\tau, f) = \int_{-\infty}^{\infty} x(t)g(\tau-t, f)e^{-i2\pi ft} dt \\ g(\tau, f) = \frac{|f|}{\sqrt{2\pi}} e^{-\left(\frac{t^2}{2\sigma^2}\right)} \end{cases} \quad (1)$$

式中:  $g(\tau, f)$  为高斯窗函数;参数  $\tau$  控制高斯窗口在时间轴上的位置;  $f$  为频率;  $t$  为时间;  $i$  为虚数单位;  $\sigma$  为标准差,在标准 S 变换中,  $\sigma = 1/|f|$ 。

离散 S 变换可由快速傅里叶变换(fast fourier transform, FFT)和卷积定理实现。对式(1),令  $f = n/NT$ ,  $\tau = jT$ ,可得到离散化 S 变换如式(2)。

$$\begin{cases} S\left[jT, \frac{n}{NT}\right] = \sum_{m=0}^{N-1} X\left[\frac{m+n}{NT}\right] e^{-\frac{2\pi^2 m^2}{n^2}} e^{\frac{i2\pi mj}{N}} \\ S(jT, 0) = \frac{1}{N} \sum_{m=0}^{N-1} x\left[\frac{m}{NT}\right] \end{cases} \quad (2)$$

式中:  $N$  为采样总点数;  $T$  为采样间隔;  $j=1,2,\dots,N-1$ ;  $n=1,2,\dots,N-1$ 。

将扰动信号进行  $S$  变换后, 得到二维矩阵  $\mathbf{S}_a$ 。矩阵每一行对应每个频率采样点, 矩阵每一列代表每个时间采样点。其中矩阵中频率点和实际频率的关系为  $(f_s/N) \times n$ ,  $f_s$  为采样频率,  $n$  为当前频率点<sup>[20]</sup>。分别求取每行的最大值 ( $F_{\max}$ )、最小值 ( $F_{\min}$ )、平均值 ( $F_{\text{mean}}$ )、标准差 ( $F_{\text{std}}$ )、均方根值 ( $F_{\text{rms}}$ ) 和每列的最大值 ( $T_{\max}$ )、最小值 ( $T_{\min}$ )、平均值 ( $T_{\text{mean}}$ )、标准差 ( $T_{\text{std}}$ )、均方根值 ( $T_{\text{rms}}$ ) 作为特征向量, 取矩阵  $\mathbf{S}_a$  和各个特征向量的最大值、最小值、平均值、均方根值、标准差组成特征  $f_1 - f_{49}$ 。另外取频域特征向量谐波畸变率和大于 100 Hz 频段的标准差以及矩阵  $\mathbf{S}_a$  大于 100 Hz 频段的标准差、高阶统计量偏度和峭度组成特征  $f_{50} - f_{61}$ 。最终得到的 61 种电能质量特征值见附录 A 表 A2, 表中各个特征量的计算方法可参考文献<sup>[21]</sup>。

### 3 基于 XGBoost 的扰动识别

XGBoost 是在梯度提升决策树 (gradient boosting decision tree, GBDT) 的基础上发展而来的一种典型的监督式集成学习算法, 其算法原理是将多个识别准确率较低的弱学习器融合为一个准确的强学习器<sup>[22]</sup>。相对于 GBDT, XGBoost 采用二阶泰勒展开简化目标函数、提高计算精度, 引入正则化项避免过拟合。同时, 在训练阶段自动执行并行计算, 优化计算资源<sup>[23]</sup>。

XGBoost 算法采用梯度提升策略, 不是一次得到所有的树, 而是每次添加一棵新树, 不断修补之前的测试结果, 其算法流程如图 1 所示。

首先将第一个学习器拟合到输入数据的整个空间, 然后将第二个学习器拟合到残差中, 以解决弱学习器分类精度低的缺点, 后面的学习器依次重复此过程, 直至满足要求。模型的最终预测结果是由每个学习器的预测之和得到的。第  $t$  次预测的结果如式(3)所示。

$$y_i^{(t)} = \sum_{k=1}^t f_k(x_i) = y_i^{(t-1)} + f_t(x_i) \quad (3)$$

式中:  $y_i^{(t)}$  为第  $t$  次预测的结果;  $f_k(x_i)$  为第  $i$  个样本在第  $k$  棵树中被分类到所在叶子节点的权重;  $y_i^{(t-1)}$  为第  $t-1$  次的预测结果;  $f_t(x_i)$  为分类和回归树的空间。

模型的目标函数由损失函数  $l$  和正则化项  $\Omega$  两部分组成, 如式(4)所示。

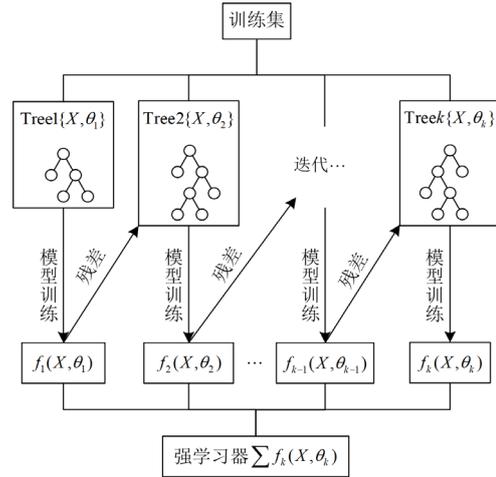


图 1 XGBoost 算法流程

Fig. 1 XGBoost algorithm flow

$$Obj^{(t)} = \sum_{i=1}^{m_{\text{smp}}} l(\hat{y}_i, y_i) + \sum_{k=1}^t \Omega(f_i) \quad (4)$$

式中: 损失函数  $l$  用来表示模型的预测能力;  $m_{\text{smp}}$  表示训练函数样本数; 正则化项  $\Omega$  用来控制树结构, 可表示为

$$\Omega(f) = \gamma T_{\text{leaf}} + \frac{1}{2} \lambda \|\omega\|^2 \quad (5)$$

式中:  $\gamma$ 、 $\lambda$  为正则化参数;  $T_{\text{leaf}}$  为叶子节点总数;  $\omega$  为叶子节点的分数值向量。

## 4 基于 ISSA 的特征选择和 XGBoost 参数优化

### 4.1 改进麻雀搜索算法

标准麻雀搜索算法 (sparrow search algorithm, SSA) 描述的是麻雀群体的觅食和反捕食行为。在觅食过程中, 群体分为发现者和跟随者。发现者具有更好的适应度, 为整个麻雀群提供觅食区域和方向, 而跟随者则利用发现者的位置获取食物。当麻雀群检测到危险并且警报值超过安全值时, 麻雀会采取行动对抗捕食者<sup>[24]</sup>。

当麻雀察觉到天敌, 需要前往安全区域时, 随着迭代次数逐渐增加, 发现者最优解范围会减小, 不易向全局最优解移动; 跟随者在向最优位置移动时, 易出现种群短时间内迅速集聚的情况, 种群的多样性骤降; 在算法迭代后期, 麻雀个体的快速同化导致容易出现局部最优停滞的情况。针对以上 3 个问题, 本文从以下 3 个方面对 SSA 进行改进。

1) 引入动态权重因子。本文在发现者位置更新公式中, 通过引入上一代全局最优解, 可以使发现

者位置受到上一代发现者位置和全局最优解的综合影响,从而有效防止算法陷入局部最优解。此外,还可以借鉴惯性权重的概念<sup>[25]</sup>,通过在发现者位置更新方式中引入动态权重因子,在迭代初期赋予较大的权重值,以促进全局探索,在迭代后期逐渐减小权重值,以进行更精细的局部搜索,从而提高算法的收敛速度。海鸥搜索算法(seagull optimization algorithm, SOA)中的非线性因子有着收敛精度高的优点,本文动态权重系数  $p$  采用 SOA 中的非线性收缩因子,其计算公式和改进后的发现者位置更新方式分别如式(6)和式(7)所示。

$$p = 2 \cdot \left( 2 \cdot \frac{t_{\text{iter}}}{T_{\text{max}}} \right) \cdot \text{rand} \quad (6)$$

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t + \omega(X_{\text{best}}^{t-1} - X_{i,j}^t), R_2 < S_1 \\ X_{i,j}^t + Q \cdot L, R_2 \geq S_1 \end{cases} \quad (7)$$

式中:  $p$  表示权重;  $\text{rand}$  为  $[0,1]$  上的随机数;  $t_{\text{iter}}$  为当前迭代次数;  $T_{\text{max}}$  表示最大迭代次数;  $X_{i,j}^{t+1}$  表示第  $t+1$  次迭代时麻雀位置;  $X_{\text{best}}^{t-1}$  表示在第  $t-1$  次迭代时麻雀的最佳位置;  $X_{i,j}^t$  表示第  $t$  次迭代时麻雀位置;  $Q$  表示服从标准正态分布的随机数;  $L$  表示大小为  $1 \times d$  维且元素均为 1 的矩阵;  $R_2$  表示  $[0,1]$  的一个随机数,即警戒值;  $S_1$  表示在  $[0.5,1]$  上的安全阈值。

2) levy 飞行策略。在跟随者的位置更新公式中引入 levy 飞行策略。levy 飞行是一种步长服从重尾概率分布的随机行走,其可以在短距离游走和长距离跳跃中随机变换。自然界中很多生物在不确定的环境中进行觅食时,都采用 levy 飞行策略<sup>[26]</sup>。改进后的跟随者位置更新公式如式(8)所示。

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}} - X_{i,j}^t}{i^2}\right), i > \frac{n}{2} \\ X_{\text{best}}^{t+1} \cdot K_{\text{levy}} + |X_{i,j}^t - X_{\text{best}}^{t+1}| A^+ L, \text{其他} \end{cases} \quad (8)$$

式中:  $X_{\text{worst}}$  表示当前最差位置;  $K_{\text{levy}}$  表示飞行的随机步长;  $A^+ = A^T(AA^T)^{-1}$ ,  $A$  表示一个只含有 1 或 -1 元素的  $1 \times d$  维矩阵。

levy 飞行的随机步长的计算公式如式(9)所示。

$$K_{\text{levy}} = \frac{u}{|v|^{\frac{1}{\beta}}} \quad (9)$$

式中:  $u$  和  $v$  都是服从正态分布的一个  $1 \times d$  维的随机矩阵,且  $u \sim (0, \sigma_1^2)$ 、 $v \sim (0,1)$ ;  $\beta$  是常数,其值为 1.5。其中  $\sigma_1$  如式(10)所示。

$$\sigma_1 = \left( \frac{\Gamma(1+\beta) \cdot \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1+\beta}{2}\right) \cdot \beta \cdot 2^{\left(\frac{\beta-1}{2}\right)}} \right) \quad (10)$$

3) 自适应贪婪、变异策略。本文将精英差分变异策略和透镜成像的动态反向学习策略融入到 SSA 中,利用判定系数  $r$  对最优麻雀位置进行混合变异扰动<sup>[27]</sup>。如式(11)所示,当  $r > 0.5$  时,采用精英差分策略进行扰动;当  $r \leq 0.5$  时,采用透镜成像的动态反向学习策略进行扰动。两种策略的应用使得算法能够跳出局部极值空间,提高在不同优化问题中的适应性。

$$x'_{\text{best}} = \begin{cases} r_1(x_2 - x_{\text{best}}) + r_2(x_3 - x_{\text{best}}), r > 0.5 \\ \frac{x_{\text{ub}} + x_{\text{lb}}}{2} + \frac{x_{\text{ub}} + x_{\text{lb}}}{2k_{\text{sf}}} + \frac{x_{\text{best}}}{k_{\text{sf}}}, r \leq 0.5 \end{cases} \quad (11)$$

式中:  $x'_{\text{best}}$  表示经过混合变异扰动后的麻雀位置;  $r$ 、 $r_1$ 、 $r_2$  为  $[0,1]$  上的随机数;  $x_{\text{ub}}$ 、 $x_{\text{lb}}$  分别为麻雀位置的取值上下限;  $x_{\text{best}}$  为最优解,  $x_2$  为次优解,  $x_3$  为第 3 优解;  $k_{\text{sf}}$  为缩放因子,控制  $x'_{\text{best}}$  和  $x_{\text{best}}$  的距离。较小的缩放因子生成的  $x'_{\text{best}}$  范围更大,而较大的缩放因子则相反。根据智能算法的特点,更希望算法在前期收敛速度快,而后迭代精度高,故本文对缩放因子  $k$  进行动态调整。

$$k = \exp(1 + 10^3 (t/T_{\text{max}})^{1/2}) \quad (12)$$

变异后的麻雀位置不一定比原始位置具有更高的收敛精度。因此,为了确保算法的进步,采用贪婪策略来决定是否使用变异解替代原始解。只有当变异解的适应度值优于原始解时,才会进行替换操作。具体的替换条件可以表示为式(13)。

$$x' = \begin{cases} x'_{\text{best}}, f(x'_{\text{best}}) < f(x_{\text{best}}) \\ x_{\text{best}}, f(x'_{\text{best}}) \geq f(x_{\text{best}}) \end{cases} \quad (13)$$

式中:  $x'$  表示经过贪婪策略后的麻雀位置;  $f(x_{\text{best}})$  表示最优位置麻雀的适应度值;  $f(x'_{\text{best}})$  表示变异后最优位置麻雀的适应度值。

经过以上 3 种方法改进后的 ISSA 算法步骤如下所述:

- 1) 初始化种群数量  $P_{\text{popsize}}$ 、最大迭代次数  $T_{\text{max}}$ 、发现者占比  $P_d$ 、警戒者占比  $S_d$ 、安全阈值  $S_1$  等参数;
- 2) 生成初始种群,计算适应度值,并进行排序,找出适应度最优个体和适应度最差个体;
- 3) 选取一定比例的适应度较优的麻雀作为发现者,其按照式(7)进行位置更新;
- 4) 其余麻雀作为跟随者,按照式(8)进行位置更新;

5) 随机选择一定比例的麻雀作为警戒者, 并更新其位置;

6) 根据概率  $P$ , 选择精英差分策略和透镜成像反向学习策略对当前最优解进行扰动, 产生新解;

7) 根据贪婪规则式(13), 确定是否进行位置更新;

8) 判断是否达到结束条件, 达到结束条件即进行下一步, 否则返回步骤 3);

9) 程序结束, 输出结果。

#### 4.2 优化特征选择和 XGBoost 扰动识别

S 变换提取的 61 个特征可能存在无用或干扰特征, 同时 XGBoost 的参数设置在很大程度上决定了模型的性能。本文采用 ISSA 优化特征选择和 XGBoost 参数。

首先, 将提取的特征和参数都用麻雀表示。麻雀由两部分组成: 1) 用来表示 S 变换提取的 61 个特征, 61 个特征的搜索空间为 0 或 1, 其中 0 表示该特征维度无效, 1 表示该特征维度有效; 2) 用来表示 XGBoost 中的参数。表 1 列出了 XGBoost 中参数的优化范围。

表 1 XGBoost 参数表

Table 1 XGBoost parameter table

XGBoost 参数	范围
eta	[0,1]
max_depth	[0,∞]
gamma	[0,∞]
subsample	(0,1]
min_child_weight	[0,∞]
colsample_bytree	(0,1]

然后将识别精度和特征选择数量设为目标函数, 可定义为

$$F_{\text{fitness}}^i = \omega_A \cdot f_{\text{acc}}^i + \omega_F \cdot \left[ 1 - \frac{\left( \sum_{j=1}^{n_f} f_j \right)}{n_f} \right] \quad (14)$$

式中:  $F_{\text{fitness}}^i$  为目标函数, 即 SSA 算法的适应度;  $\omega_A$  为 XGBoost 分类精度的权重;  $f_{\text{acc}}^i$  为 XGBoost 分类精度;  $\omega_F$  为所选特征数量的权重;  $f_j$  表示是否选择了特征  $j$  ( $f_j = 0$  或  $f_j = 1$ );  $n_f$  为特征总数。采用 ISSA 优化特征选择和 XGBoost 参数的主要流程如图 2 所示。

## 5 算例分析

根据附录 A 表 A1 中参数范围, 在 Matlab 2020a 中对 PQDs 进行仿真, 对每种扰动随机生成 200 个样本, 共 3800 个样本。在 3800 个样本中随机选取

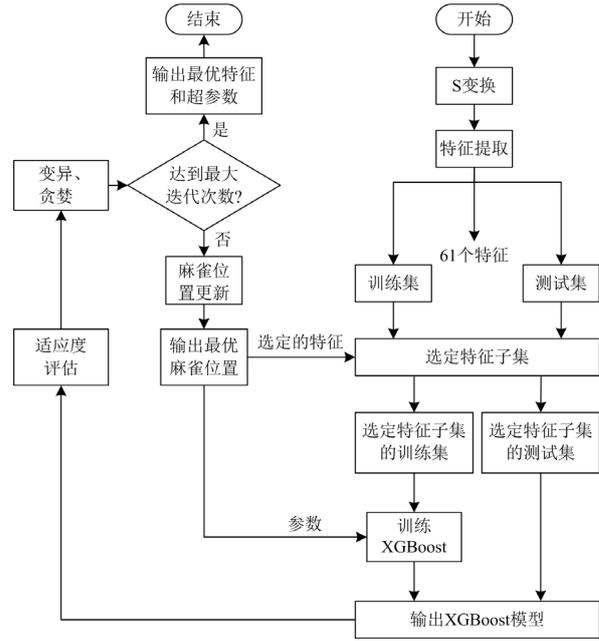


图 2 基于 ISSA 的特征选择与参数优化流程图

Fig. 2 Flow chart of feature selection and parameter optimization based on ISSA

70%为训练集, 剩余的 30%为测试集。

#### 5.1 ISSA 算法性能测试

为了评估 ISSA 算法的有效性, 本文选取 3 种测试函数(详见表 2)来进行算法性能测试, 并与粒子群优化(particle swarm optimization, PSO)算法、鲸鱼优化算法(whale optimization algorithm, WOA)、野犬优化算法(dingo optimization algorithm, DOA)、灰狼优化算法(grey wolf optimizer, GWO)、SSA 等算法进行比较。

表 2 测试函数

Table 2 Test functions

计算公式	范围	最优解
$f_1 = \sum_{i=1}^n x_i^2$	[-100,100]	0
$f_2 = \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i) + 10)$	[-5.12,5.12]	0
$f_3 = 418.9829d - \sum_{i=1}^n x_i \sin(\sqrt{ x_i })$	[-500,500]	0

所有算法中种群数量设置为 100, 迭代次数为 1000。PSO 算法中, 设置惯性因子  $w$  为 0.729, 学习因子  $C_1$  和  $C_2$  均为 1.494 45; WOA 中, 设置控制参数  $a$  从 2 线性递减至 0; DOA 中, 设置生存率  $S$  为 0.3; SSA 和 ISSA 中, 发现者占比  $P_d$  为 20%, 警戒者占比  $S_d$  为 20%, 安全阈值  $S_f$  为 0.8。

3 种测试函数的收敛曲线分别如图 3—图 5 所示。其中, 横轴为迭代次数, 纵轴为适应度值(以 e

为底的自然对数  $\ln$ )。对数值越低,代表寻优精度越高。由图 3—图 5 可以看出,PSO 的收敛精度最低,而且容易陷入局部最优解,GWO、WOA 和 SSA 在精度和速度上都要优于 PSO,而 ISSA 在收敛速度方面表现出色,能够在较少的迭代次数内快速收敛到最优解,并且具备更高的精度。通过对单峰和多峰函数的测试可以得出结论,ISSA 能够有效避免陷入局部最优解,具备卓越的探索能力。

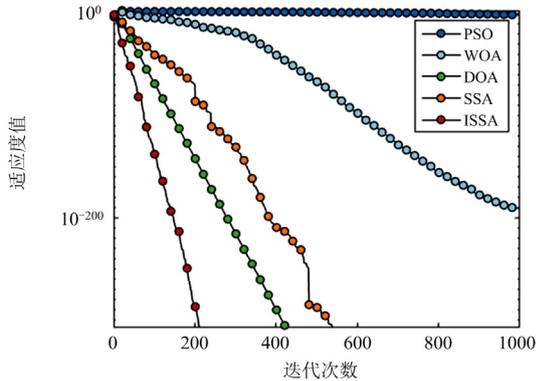


图 3 测试函数  $f_1$  收敛曲线  
Fig. 3 Convergence curve of test function  $f_1$

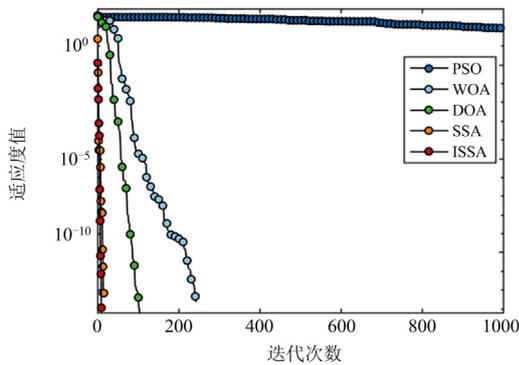


图 4 测试函数  $f_2$  收敛曲线  
Fig. 4 Convergence curve of test function  $f_2$

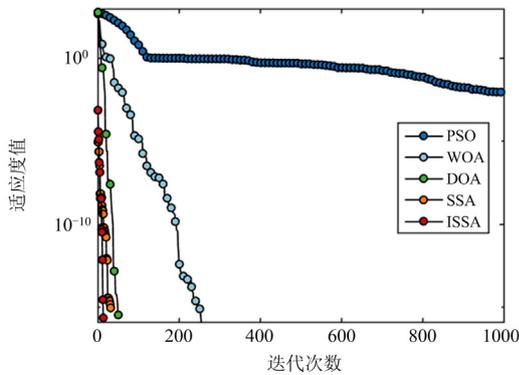


图 5 测试函数  $f_3$  收敛曲线  
Fig. 5 Convergence curve of test function  $f_3$

### 5.2 特征选择结果分析

采用 S 变换从样本中提取 61 个特征,在不同噪声情况下,将 ISSA 特征优化与未进行特征优化的适应度值进行对比分析。将精度的权重  $\omega_A$  调整为 95%,特征数量的权重  $\omega_F$  设置为 5%。ISSA 参数设置如表 3 所示。

表 3 ISSA 参数

Table 3 ISSA parameters

ISSA 参数	数值
麻雀数量	5
迭代次数	20
发现者占比	0.2
警戒者占比	0.2
警戒值	0.8

特征优化前后准确率对比如图 6 所示。根据式 (13),未进行特征优化的曲线实际是对样本提取 61 个特征后的准确率加上惩罚项曲线。

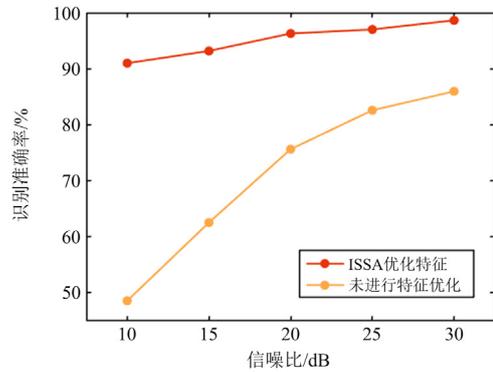


图 6 特征优化前后准确率对比  
Fig. 6 Accuracy comparison before and after feature optimization

随着信噪比的增加,两种方法的适应度值都呈上升趋势,但经过特征优化的方法上升平滑且缓慢,而未经过优化的方法,上升迅速。这是因为信噪比越低,PQDs 中的噪声含量越高,不同类型 PQDs 之间的特征被噪声淹没,增加了扰动识别的难度。在噪声强度为 30 dB 时,由于惩罚项的作用,经过 ISSA 优化特征选择的方法比未经过特征优化的方法适应度值高 12.68%。

### 5.3 不同噪声情况下对比分析

为验证所提方法在不同噪声情况下的抗噪能力,首先将扰动样本分为训练集和测试集,分别向训练集和测试集中添加信噪比为 40 dB、30 dB 和 20 dB 的噪声,在不同噪声环境下训练 ISSA-XGBoost 模型。最后基于测试集求得不同信噪比下扰动的分类准确率见表 4。

表 4 中 C1—C9 为单类型扰动,C10—C19 为复

合类型扰动。由表 4 可以看出, 信噪比减小, 信号收到的干扰会增大, 而模型识别准确率会随之减小。当信噪比为 30 dB 时, ISSA-XGBoost 对单类型扰动和复合类型扰动的平均识别准确率可以达到 98.63%, 当信噪比为 20 dB 时, 模型对扰动的平均识别准确率仍然可以达到 96.28%。结果表明, 本文提出的方法分类效果良好且鲁棒性较强, 不易受环境噪声影响。

表 4 不同噪声情况下识别准确率

Table 4 Recognition accuracy under different noise conditions

扰动类型	识别准确率/%		
	40 dB	30 dB	20 dB
C1	99.17	99.17	97.50
C2	100.00	100.00	99.17
C3	100.00	100.00	99.17
C4	100.00	100.00	100.00
C5	99.17	99.17	91.67
C6	98.33	98.33	91.67
C7	99.17	99.17	97.50
C8	98.33	98.33	95.83
C9	99.17	98.33	95.83
C10	99.17	99.17	98.33
C11	97.50	97.50	96.67
C12	99.17	98.33	96.67
C13	99.17	98.33	95.83
C14	98.33	98.33	95.83
C15	97.50	96.67	91.67
C16	99.17	98.33	97.50
C17	98.33	98.33	97.50
C18	97.50	97.50	95.83
C19	99.17	98.33	92.50
平均	98.84	98.63	96.28

#### 5.4 不同分类模型对比分析

为验证本文所提出的基于改进麻雀搜索算法的 XGBoost 模型的有效性, 将本文方法和 KNN、DT、GBDT 和 XGBoost 4 种模型在不同噪声环境下进行比较, 并将所得平均测试准确率与本文方法进行对比, 结果如图 7 所示。

从图 7 可以看出, 在信噪比为 20 dB 时, 传统

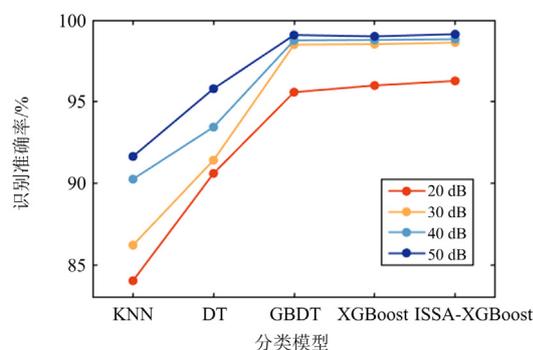


图 7 不同分类模型识别结果

Fig. 7 Identification results of different classification models

的机器学习算法 KNN 和 DT 的识别准确率分别为 84.04%和 90.61%, 集成学习算法 GBDT 和 XGBoost 识别准确率分别为 95.59%和 95.71%, 本文提出的 ISSA-XGBoost 算法识别准确率最高, 为 96.28%。本文所提出的算法在 30 dB、40 dB 和 50 dB 噪声强度下, 有 98.63%、98.84%和 99.14%的准确率, 分别高出 GBDT 算法<sup>[17]</sup>0.13%、0.08%和 0.05%。

#### 5.5 不同启发式算法优化 XGBoost 的识别性能对比分析

为了验证 ISSA 优化 XGBoost 模型的优越性, 与 PSO-XGBoost、SSA-XGBoost 模型进行对比分析, PSO、SSA 和 ISSA 的种群数目为 5, 迭代次数为 20。信噪比设置为 30 dB, 适应度值随迭代次数变化曲线如图 8 所示。

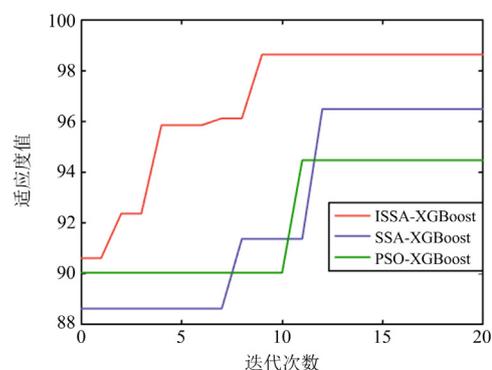


图 8 适应度值变化曲线

Fig. 8 Fitness change curve

根据图 8 的结果, 可以得出以下结论: 在这 3 种优化算法中, PSO 算法表现出较慢的收敛速度, 并且其适应度值最低。SSA 由于全局搜索能力较弱且局部开发能力不强, 需要经过 12 次迭代才能达到全局最优解。而改进后的 ISSA 在仅经过 9 次迭代后就达到了收敛状态, 并且具有最高的适应度值。这说明改进的 ISSA 相比其他两种优化算法, 在寻找使得 XGBoost 模型达到最优的特征和参数方面更快速且更有效。

图 9 为 PSO-XGBoost、SSA-XGBoost 和 ISSA-XGBoost 的识别结果图。

可以看出, 以上 3 种模型对单扰动的识别准确率都非常高, PSO-XGBoost 有 9 个样本识别错误, SSA-XGBoost 有 7 个样本识别错误, ISSA-XGBoost 仅有 5 个样本识别错误, 并且这 21 个样本都是将暂态振荡和暂态脉冲互相识别错误。对于复合类型扰动, ISSA-XGBoost 仅有 26 个样本识别错误。整体来说 ISSA-XGBoost 识别精度仍比其他两种模型分别高出 2.14%和 4.16%。实验表明采用 ISSA 优化的 XGBoost 模型具有更高的识别精度。

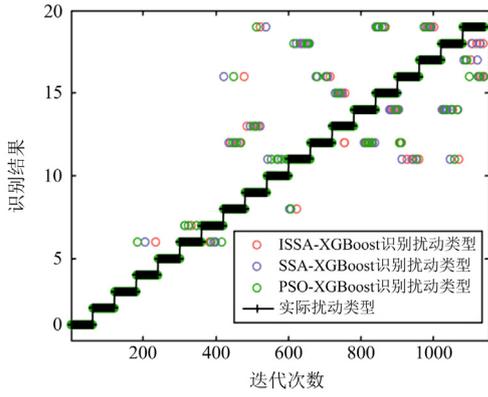


图 9 不同优化算法识别结果图

Fig. 9 Identification result of different optimization algorithms

## 6 结论

为了解决 PQDs 识别中存在特征冗余和识别方法精度低的问题, 本文提出了一种基于 ISSA-XGBoost 算法的电能质量扰动识别方法。实验表明, 该方法在噪声环境下可以更高效地找到最优特征子集, 并具有较高的识别精度。本文的主要结论如下:

1) 与 PSO、WOA、DOA、SSA 相比, 提出的 ISSA-XGBoost 算法具有更快的搜索全局最优解的能力, 不易陷入局部最优解。

2) 与 PSO-XGBoost 和 SSA-XGBoost 方法相比, 本文所提方法能更快地找到最优特征子集和 XGBoost 模型的参数, 在信噪比为 20~40 dB 的噪声环境下分别有 96.28%、98.63% 和 98.84% 的准确率。

## 附录 A

表 A1 电能质量扰动数学模型

Table A1 Mathematical model of power quality disturbance

扰动类型	数学模型	参数范围
无扰动(C0)	$y(t) = A \sin(\omega t)$	$A = 1 \text{ p.u.}; \omega = 100\pi \text{ rad/s}$
电压暂升(C1)	$y(t) = A[1 + \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t)$	$0.1 \leq \alpha \leq 0.8; T \leq t_2 - t_1 \leq 9T$
电压暂降(C2)	$y(t) = A[1 - \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t)$	$0.1 \leq \alpha \leq 0.9; T \leq t_2 - t_1 \leq 9T$
电压中断(C3)	$y(t) = A[1 - \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t)$	$0.9 \leq \alpha \leq 1; T \leq t_2 - t_1 \leq 9T$
电压闪变(C4)	$y(t) = [1 + \lambda \sin(k\omega t)]\sin(\omega t)$	$0.1 \leq \lambda \leq 0.2; 0.1 \leq k \leq 0.4$
暂态振荡(C5)	$y(t) = \sin(\omega t) + \beta_1 e^{-(t-t_3)/\tau} \sin(2\pi f_n(t-t_3))(u(t-t_3) - u(t-t_4))$	$0.1 \leq \beta_1 \leq 0.8; 0.5T \leq t_4 - t_3 \leq 3T; 0.008 \leq \tau \leq 0.03;$ $300 \text{ Hz} \leq f_n \leq 900 \text{ Hz}$
暂态脉冲(C6)	$y(t) = \sin(\omega t) + \beta_2 e^{-(t-t_3)/\tau} (u(t-t_3) - u(t-t_4))$	$1 \leq \beta_2 \leq 10; 0.5T \leq t_4 - t_3 \leq 3T; 0.008 \leq \tau \leq 0.03$
谐波(C7)	$y(t) = \sin(\omega t) + \sum_{n=3}^7 \sin(n\omega t)$	$0.05 \leq a_3, a_5, a_7 \leq 0.15; \sum a_n^2 = 1$
电压暂升+谐波(C8)	$y(t) = A[1 + \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t) + \sum_{n=3}^7 \sin(n\omega t)$	$0.1 \leq \alpha \leq 0.8; T \leq t_2 - t_1 \leq 9T; 0.05 \leq a_3, a_5, a_7 \leq 0.15; \sum a_n^2 = 1$
电压暂降+谐波(C9)	$y(t) = A[1 - \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t) + \sum_{n=3}^7 \sin(n\omega t)$	$0.1 \leq \alpha \leq 0.9; T \leq t_2 - t_1 \leq 9T; 0.05 \leq a_3, a_5, a_7 \leq 0.15; \sum a_n^2 = 1$
电压中断+谐波(C10)	$y(t) = A[1 - \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t) + \sum_{n=3}^7 \sin(n\omega t)$	$0.9 \leq \alpha \leq 1; T \leq t_2 - t_1 \leq 9T; 0.05 \leq a_3, a_5, a_7 \leq 0.15; \sum a_n^2 = 1$
电压闪变+谐波(C11)	$y(t) = [1 + \lambda \sin(k\omega t)]\sin(\omega t) + \sum_{n=3}^7 \sin(n\omega t)$	$0.1 \leq \lambda \leq 0.2; 0.1 \leq k \leq 0.4; 0.05 \leq a_3, a_5, a_7 \leq 0.15; \sum a_n^2 = 1$
电压暂升+暂态振荡(C12)	$y(t) = A[1 + \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t) + \beta_1 e^{-(t-t_3)/\tau} \sin(2\pi f_n(t-t_3))(u(t-t_3) - u(t-t_4))$	$0.1 \leq \alpha \leq 0.8; T \leq t_2 - t_1 \leq 9T; 0.1 \leq \beta_1 \leq 0.8;$ $0.5T \leq t_4 - t_3 \leq 3T; 0.008 \leq \tau \leq 0.03; 300 \text{ Hz} \leq f_n \leq 900 \text{ Hz}$
电压暂降+暂态振荡(C13)	$y(t) = A[1 - \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t) + \beta_1 e^{-(t-t_3)/\tau} \sin(2\pi f_n(t-t_3))(u(t-t_3) - u(t-t_4))$	$0.1 \leq \alpha \leq 0.9; T \leq t_2 - t_1 \leq 9T; 0.1 \leq \beta_1 \leq 0.8;$ $0.5T \leq t_4 - t_3 \leq 3T; 0.008 \leq \tau \leq 0.03; 300 \text{ Hz} \leq f_n \leq 900 \text{ Hz}$
电压闪变+暂态振荡(C14)	$y(t) = [1 + \lambda \sin(k\omega t)]\sin(\omega t) + \beta_1 e^{-(t-t_3)/\tau} \sin(2\pi f_n(t-t_3))(u(t-t_3) - u(t-t_4))$	$0.1 \leq \lambda \leq 0.2; 0.1 \leq k \leq 0.4; 0.1 \leq \beta_1 \leq 0.8;$ $0.5T \leq t_4 - t_3 \leq 3T; 0.008 \leq \tau \leq 0.03; 300 \text{ Hz} \leq f_n \leq 900 \text{ Hz}$
谐波+暂态振荡(C15)	$y(t) = \sin(\omega t) + \sum_{n=3}^7 \sin(n\omega t) + \beta_1 e^{-(t-t_3)/\tau} \sin(2\pi f_n(t-t_3))(u(t-t_3) - u(t-t_4))$	$0.05 \leq a_3, a_5, a_7 \leq 0.15; \sum a_n^2 = 1; 0.1 \leq \beta_1 \leq 0.8;$ $0.5T \leq t_4 - t_3 \leq 3T; 0.008 \leq \tau \leq 0.03; 300 \text{ Hz} \leq f_n \leq 900 \text{ Hz}$
电压暂升+暂态脉冲(C16)	$y(t) = A[1 + \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t) + \beta_2 e^{-(t-t_3)/\tau} (u(t-t_3) - u(t-t_4))$	$0.1 \leq \alpha \leq 0.8; T \leq t_2 - t_1 \leq 9T; 1 \leq \beta_2 \leq 10;$ $0.5T \leq t_4 - t_3 \leq 3T; 0.008 \leq \tau \leq 0.03$
电压暂降+暂态脉冲(C17)	$y(t) = A[1 - \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t) + \beta_2 e^{-(t-t_3)/\tau} (u(t-t_3) - u(t-t_4))$	$0.1 \leq \alpha \leq 0.9; T \leq t_2 - t_1 \leq 9T; 1 \leq \beta_2 \leq 10;$ $0.5T \leq t_4 - t_3 \leq 3T; 0.008 \leq \tau \leq 0.03$
电压闪变+暂态脉冲(C18)	$y(t) = A[1 - \alpha(u(t-t_1) - u(t-t_2))]\sin(\omega t) + \beta_2 e^{-(t-t_3)/\tau} (u(t-t_3) - u(t-t_4))$	$0.1 \leq \lambda \leq 0.2; 0.1 \leq k \leq 0.4; 1 \leq \beta_2 \leq 10;$ $0.5T \leq t_4 - t_3 \leq 3T; 0.008 \leq \tau \leq 0.03$
谐波+暂态脉冲(C19)	$y(t) = \left( \sin(\omega t) + \sum_{n=3}^7 \sin(n\omega t) \right) + \beta_2 e^{-(t-t_3)/\tau} (u(t-t_3) - u(t-t_4))$	$0.05 \leq a_3, a_5, a_7 \leq 0.15; \sum a_n^2 = 1; 1 \leq \beta_2 \leq 10;$ $0.5T \leq t_4 - t_3 \leq 3T; 0.008 \leq \tau \leq 0.03$

表 A2 61 种 PQDs 特征

Table A2 61 kinds of PQDs characteristics

PQDs 特征	$F_1$	$F_2$	$F_3$	$F_4$	$F_5$	$F_6$	$F_7$	$F_8$	$F_9$
$S_a$	$f_1$	$f_{12}$	$f_{23}$	$f_{32}$	$f_{41}$	$f_{50}$	—	$f_{60}$	$f_{61}$
$T_{max}$	$f_2$	$f_{13}$	$f_{24}$	$f_{33}$	$f_{42}$	—	—	—	—
$T_{min}$	$f_3$	$f_{14}$	$f_{25}$	$f_{34}$	$f_{43}$	—	—	—	—
$T_{mean}$	$f_4$	$f_{15}$	—	$f_{35}$	$f_{44}$	—	—	—	—
$T_{std}$	$f_5$	$f_{16}$	$f_{26}$	—	$f_{45}$	—	—	—	—
$T_{rms}$	$f_6$	$f_{17}$	$f_{27}$	$f_{36}$	—	—	—	—	—
$F_{max}$	$f_7$	$f_{18}$	$f_{28}$	$f_{37}$	$f_{46}$	$f_{51}$	$f_{55}$	—	—
$F_{min}$	$f_8$	$f_{19}$	$f_{29}$	$f_{38}$	$f_{47}$	$f_{52}$	$f_{56}$	—	—
$F_{mean}$	$f_9$	$f_{20}$	—	$f_{39}$	$f_{48}$	$f_{53}$	$f_{57}$	—	—
$F_{std}$	$f_{10}$	$f_{21}$	$f_{30}$	—	$f_{49}$	—	$f_{58}$	—	—
$F_{rms}$	$f_{11}$	$f_{22}$	$f_{31}$	$f_{40}$	—	$f_{54}$	$f_{59}$	—	—

## 参考文献

- [1] 李琦, 许素安, 施阁, 等. 基于 S 变换和 IWOA-SVM 的复合电能质量扰动识别[J]. 智慧电力, 2023, 51(5): 30-35, 50.  
LI Qi, XU Su'an, SHI Ge, et al. Identification of composite power quality disturbance based on S-transform and IWOA-SVM[J]. Smart Power, 2023, 51(5): 30-35, 50.
- [2] 汪飞, 全晓庆, 任林涛. 电能质量扰动检测与识别方法研究综述[J]. 中国电机工程学报, 2021, 41(12): 4104-4121.  
WANG Fei, QUAN Xiaoqing, REN Lintao. Review of power quality disturbance detection and identification methods[J]. Proceedings of the CSEE, 2021, 41(12): 4104-4121.
- [3] 奚鑫泽, 邢超, 覃日升, 等. 基于多层特征融合注意力网络的电能质量扰动识别方法[J]. 智慧电力, 2022, 50(10): 37-44.  
XI Xinze, XING Chao, QIN Risheng, et al. Power quality disturbance recognition method based on multi-layer feature fusion attention network[J]. Smart Power, 2022, 50(10): 37-44.
- [4] 吴怀诚, 刘家强, 岳蕾, 等. 基于多特征融合的卷积神经网络的电能质量扰动识别方法[J]. 电网与清洁能源, 2023, 39(9): 19-23, 31.  
WU Huaicheng, LIU Jiaqiang, YUE Lei, et al. Identification of power quality disturbances based on MFCNN[J]. Power System and Clean Energy, 2023, 39(9): 19-23, 31.
- [5] KHOKHAR S, ZIN A A M, MEMON A P, et al. A new optimal feature selection algorithm for classification of power quality disturbances using discrete wavelet transform and probabilistic neural network[J]. Measurement, 2017, 95: 246-259.
- [6] 黄建明, 瞿合祚, 李晓明. 基于短时傅里叶变换及其谱峭度的电能质量混合扰动分类[J]. 电网技术, 2016, 40(10): 3184-3191.  
HUANG Jianming, QU Hezuo, LI Xiaoming. Classification for hybrid power quality disturbance based on STFT and its spectral Kurtosis[J]. Power System Technology, 2016, 40(10): 3184-3191.
- [7] 肖贤贵, 李开成, 蔡得龙, 等. 一种电能质量扰动信号的联合去噪算法[J]. 电工技术学报, 2021, 36(21): 4418-4428.  
XIAO Xiangui, LI Kaicheng, CAI Delong, et al. A combined de-noising method for power quality disturbances events[J]. Transactions of China Electrotechnical Society, 2021, 36(21): 4418-4428.
- [8] 李祖明, 吕干云, 陈诺, 等. 基于混沌集成决策树的电能质量复合扰动识别[J]. 电力系统保护与控制, 2021, 49(21): 18-27.  
LI Zuming, LÜ Ganyun, CHEN Nuo, et al. Recognition of hybrid PQ disturbances based on a chaos ensemble decision tree[J]. Power System Protection and Control, 2021, 49(21): 18-27.
- [9] MAHELA O P, SHAIK A G. Recognition of power quality disturbances using S-transform based ruled decision tree and fuzzy C-means clustering classifiers[J]. Applied Soft Computing, 2017, 59: 243-257.
- [10] 商立群, 侯亚东, 黄辰浩, 等. 基于 IDOA-DHKELM 的变压器故障诊断[J]. 高电压技术, 2023, 49(11): 4726-4735.  
SHANG Liqun, HOU Yadong, HUANG Chenhao, et al. Transformer fault diagnosis based on IDOA- DHKELM[J]. High Voltage Engineering, 2023, 48(11): 4726-4735.
- [11] 阮宇航, 肖先勇, 胡文曦, 等. 基于多粒度特征选择和模型融合的复合电能质量扰动分类特征优化[J]. 电力系统保护与控制, 2022, 50(14): 1-10.  
RUAN Zihang, XIAO Xianyong, HU Wenxi, et al. Multiple power quality disturbance classification feature optimization based on multi-granularity feature selection and model fusion[J]. Power System Protection and Control, 2022, 50(14): 1-10.
- [12] 张明龙, 张振宇, 罗翔, 等. 基于多核支持向量机的混合扰动波形辨识算法研究[J]. 电力系统保护与控制, 2022, 50(15): 43-49.  
ZHANG Minglong, ZHANG Zhenyu, LUO Xiang, et al. Complex disturbance waveform recognition based on a multi-kernel support vector machine[J]. Power System Protection and Control, 2022, 50(15): 43-49.
- [13] 贺虎成, 王承海, 辛钟毓, 等. 一种组合重构的电能质量扰动特征提取方法[J]. 电力系统保护与控制, 2023, 51(10): 34-44.

- HE Hucheng, WANG Chenghai, XIN Zhongyu, et al. A feature extraction method for power quality disturbance based on reconstructed combination[J]. *Power System Protection and Control*, 2023, 51(10): 34-44.
- [14] 王艳丽, 梁静, 薛冰, 等. 基于进化计算的特征选择方法研究概述[J]. *郑州大学学报(工学版)*, 2020, 41(1): 49-57.
- WANG Yanli, LIANG Jing, XUE Bing, et al. Research on evolutionary computation for feature selection[J]. *Journal of Zhengzhou University (Engineering Science)*, 2020, 41(1): 49-57.
- [15] CHAMCHUEN S, SIRITARATIWAT A, FUANGFOO P, et al. Adaptive salp swarm algorithm as optimal feature selection for power quality disturbance classification[J]. *Applied Sciences*, 2021, 11(12): 5670.
- [16] SINGH U, SINGH S N. Optimal feature selection via NSGA-II for power quality disturbances classification[J]. *IEEE Transactions on Industrial Informatics*, 2017, 14(7): 2994-3002.
- [17] 吴建章, 梅飞, 郑建勇, 等. 基于改进经验小波变换和 XGBoost 的电能质量复合扰动分类[J]. *电工技术学报*, 2022, 37(1): 232-243, 253.
- WU Jianzhang, MEI Fei, ZHENG Jianyong, et al. Recognition of multiple power quality disturbances based on modified empirical wavelet transform and XGBoost[J]. *Transactions of China Electrotechnical Society*, 2022, 37(1): 232-243, 253.
- [18] PANIGRAHI R R, MISHRA M, NAYAK J, et al. A power quality detection and classification algorithm based on FDST and hyper-parameter tuned light-GBM using memetic firefly algorithm[J]. *Measurement*, 2022, 187: 110260.
- [19] Recommended practice for monitoring electric power quality: IEEE 1159—2009[S].
- [20] 吴禹, 唐求, 滕召胜, 等. 基于改进 S 变换的电能质量扰动信号特征提取方法[J]. *中国电机工程学报*, 2016, 36(10): 2682-2689.
- WU Yu, TANG Qiu, TENG Zhaosheng, et al. Feature extraction method of power quality disturbance signals based on modified S-transform[J]. *Proceedings of the CSEE*, 2016, 36(10): 2682-2689.
- [21] 许立武, 李开成, 罗奕, 等. 基于不完全 S 变换与梯度提升树的电能质量复合扰动识别[J]. *电力系统保护与控制*, 2019, 47(6): 24-31.
- XU Liwu, LI Kaicheng, LUO Yi, et al. Classification of complex power quality disturbances based on incomplete S-transform and gradient boosting decision tree[J]. *Power System Protection and Control*, 2019, 47(6): 24-31.
- [22] BENTÉJAC C, CSÖRGŐ A, MARTÍNEZ-MUÑOZ G. A comparative analysis of gradient boosting algorithms[J]. *Artificial Intelligence Review*, 2021, 54: 1937-1967.
- [23] JIANG H, HE Z, YE G, et al. Network intrusion detection based on PSO-XGBoost model[J]. *IEEE Access*, 2020, 8: 58392-58401.
- [24] 毛清华, 张强. 融合柯西变异和反向学习的改进麻雀算法[J]. *计算机科学与探索*, 2021, 15(6): 1155-1164.
- MAO Qinghua, ZHANG Qiang. Improved sparrow algorithm combining Cauchy mutation and opposition-based learning[J]. *Journal of Frontiers of Computer Science and Technology*, 2021, 15(6): 1155-1164.
- [25] 李大海, 李鑫, 王振东. 融合多策略的增强麻雀搜索算法及其应用[J]. *计算机应用研究*, 2023, 40(10): 3032-3039.
- LI Dahai, LI Xin, WANG Zhendong. Enhanced sparrow search algorithm with multiple strategies and its application[J]. *Application Research of Computers*, 2023, 40(10): 3032-3039.
- [26] YANG X S, DEB S. Multiobjective cuckoo search for design optimization[J]. *Computers & Operations Research*, 2013, 40(6): 1616-1624.
- [27] 李大海, 伍兆前, 王振东. 融合牵引变异和透镜成像的花授粉算法及应用[J]. *计算机工程与应用*, 2023, 59(14): 76-85.
- LI Dahai, WU Zhaoqian, WANG Zhendong. A flower pollination algorithm combining lens imaging and traction mutation and its application[J]. *Computer Engineering and Applications*, 2023, 59(14): 76-85.

收稿日期: 2023-10-02; 修回日期: 2023-12-11

作者简介:

商立群(1968—), 男, 博士, 教授, 研究方向为电力系统分析与控制、过电压保护; E-mail: shanglq@xust.edu.cn

李朝彪(1999—), 男, 硕士研究生, 研究方向为电能质量扰动识别。E-mail: 2282859033@qq.com

(编辑 魏小丽)