

DOI: 10.19783/j.cnki.pspc.211372

基于多核支持向量机的混合扰动波形辨识算法研究

张明龙¹, 张振宇¹, 罗翔¹, 高源¹, 李宽宏², 朱珂³

(1. 国网福建省电力有限公司电力科学研究院, 福建 福州 350007; 2. 国网福建省电力有限公司福州供电公司, 福建 福州 350009; 3. 山东大学电气工程学院, 山东 济南 250061)

摘要: 针对特征提取手段自身局限性导致的扰动典型特征间边缘重叠对混和扰动辨识的影响, 提出一种基于多域特征优选的多核支持向量机辨识算法。首先, 利用多种特征提取手段获取混和扰动多域典型特征。其次, 为考虑高维特征与目标类别的相关性和度量尺度的规范化, 利用改进的最大相关最小冗余准则优选用于辨识的关键特征子集, 进而利用计及半径信息的多核 SVM 来辨识混合扰动波形。仿真结果表明, 所提辨识算法能够克服混合扰动特征空间模糊对辨识精度的影响, 受噪声影响小, 稳定性好。

关键词: 混合扰动; 多域; 多核支持向量机; 边缘重叠; 配电网

Complex disturbance waveform recognition based on a multi-kernel support vector machine

ZHANG Minglong¹, ZHANG Zhenyu¹, LUO Xiang¹, GAO Yuan¹, LI Kuanhong², ZHU Ke³

(1. Electrical Power Research Institute, State Grid Fujian Electric Power Co., Ltd., Fuzhou 350007, China;

2. Fuzhou Power Supply Company, State Grid Fujian Electric Power Co., Ltd., Fuzhou 350009, China;

3. School of Electrical Engineering, Shandong University, Jinan 250061, China)

Abstract: There is influence of edge overlap among disturbed typical features on complex disturbance identification due to the limitations of feature extraction methods. Thus a multi-kernel support vector machine identification algorithm based on multi-domain feature optimization is proposed. First, a variety of feature extraction methods are used to obtain the complex perturbation multi-domain typical features. Secondly, in order to consider the correlation between high-dimensional features and target categories and the normalization of the measurement scale, an improved maximum correlation minimum redundancy criterion is used to select the key feature subset for identification, and then the multi-kernel SVM with radius information is used to identify the complex disturbance waveform. The simulation results show that the proposed algorithm can overcome the influence of spatial ambiguity of complex disturbance on identification accuracy, is less affected by noise and has good stability.

This work is supported by the Science and Technology Project of the Headquarters of the State Grid Corporation of China (No. 52130421000S).

Key words: complex disturbance; multi-domain; multi-kernel support vector machine; edge overlap; distribution network

0 引言

电能质量扰动(Power Quality Disturbance, PQD)种类多样^[1-3], 能否将各种 PQD 信号在大量波形数据中准确识别出来, 对后续扰动分析和相关抑制措施的选取具有重要意义。

基金项目: 国家电网有限公司总部科技项目资助“基于物联网技术的配电开关一二次深度融合与精益运维关键技术研究及应用”(52130421000S)

电能质量扰动识别算法的研究多年来备受关注。文献[4]利用短时傅里叶变换(Short Time Fourier Transform, STFT)来提取时频最大幅值相量, 并将其输入到有向无环图的支持向量机(SVM)中, 达到识别的目的; 文献[5-6]则利用发生扰动时各层小波系数和小波能量的特点并结合神经网络实现对扰动的辨识; 文献[7]利用快速 S 变换提取扰动典型特征, 进而通过决策树辨识含噪扰动。这些算法均针对单一电能质量扰动。

若多种电能质量扰动同时发生会导致特征间边

界模糊,影响混合电能质量扰动辨识的准确性^[8]。针对该问题,目前主要有两种解决方法。一种是引入窗宽调节因子来优化特征提取效率^[9-11]。然而,该方法是根据经验确定窗宽调节因子大小,且当扰动类型增多时仅按频率分成两段或者改变窗宽调节因子都将难以满足不同频率扰动的分辨率要求。另一种方法是利用分层结构结合不同的特征提取手段进行分类,该方法的正确率易受分层结构合理性的影响^[10-12]。

为避免特征提取手段自身局限性导致的扰动典型特征间边缘重叠对混和扰动辨识的影响,本文提出一种基于多域特征优选的多核支持向量机辨识算法。首先,在改进的最大相关最小冗余准则的基础上挑选对分类有效的关键特征,综合考虑特征联合作用对类别最大相关度的影响与不同特征的可比性。其次,为降低核函数与特征分布不同对分类器性能的影响,利用引入集成半径信息的多核支持向量机来开展扰动辨识。

1 混合电能质量扰动多核辨识策略

本文首先采用改进的最大相关-最小冗余(mRMR)准则算法对混和扰动典型特征进行优选,然后利用集成半径信息的多核支持向量机辨识混和扰动。

1.1 交互作用下改进 mRAR 算法

改进的最大相关-最小冗余准则算法首先引入交互信息来计及新加入特征和已有特征同时作用对分类贡献度的影响,然后引入对称不确定度将互信息规范化。

随机变量 X 、 Y 、 T 三者的交互信息为^[13]

$$MI(X;Y;T) = MI(X,Y;T) - MI(X;T) - MI(Y;T) \quad (1)$$

首先,将交互信息引入到 mRMR 准则中,以此计算目标类型与特征的相关性,可将 mRMR 准则公式改为

$$\begin{aligned} & \max_{f_i \in TF - F_{m-1}} [MI(f_i;T) + \\ & \frac{1}{m-1} \sum_{f_j \in F_{m-1}} [MI(f_i;f_j;T) - \frac{1}{m-1} \sum_{f_j \in F_{m-1}} MI(f_i;f_j)] = \\ & \max_{f_i \in TF - F_{m-1}} \frac{1}{m-1} \sum_{f_j \in F_{m-1}} [MI(f_i;f_j;T) - MI(f_j;T) - MI(f_i;f_j)] \end{aligned} \quad (2)$$

式中: TF 表示原给定特征全集; T 为目标类别; F_{m-1} 表示已有 $m-1$ 个关键特征子集; $TF - F_{m-1}$ 为剩余特征集合。选用对称不确定度^[14]对式(2)中 MI 规范化可得

$$SU(X,Y) = 2 \left[\frac{MI(X;Y)}{H(X) + H(Y)} \right] \quad (3)$$

$$SU(X,Y;T) = 2 \left[\frac{MI(X,Y;T)}{H(X,Y) + H(T)} \right] \quad (4)$$

式中: SU 表示归一化互信息; $H(X)$ 、 $H(Y)$ 、 $H(T)$ 分别为随机变量 X 、 Y 、 T 的信息熵; $H(X,Y)$ 为随机变量 X 、 Y 的联合熵。结合式(2)—式(4),将交互作用下的改进 mRAR 算法表达式等价于

$$\max_{f_i \in TF - F_{m-1}} \frac{1}{m-1} \sum_{f_j \in F_{m-1}} \{SU(f_i;f_j;T) - SU(f_j;T) - SU(f_i;f_j)\} \quad (5)$$

1.2 集成半径信息的多核 SVM 算法

设有 n 个样本,依照种类的区别记为 $\{x_{j,s}; j=1,2,L,k; s=1,2,L,n_j\}$,其中 j 表示样本的类型, n_j 表示第 j 类样本的样本数, k 表示目标类型的数量。 M 为全部样本映射至第 m 个特征空间中样本的均值。 $M_j = 1/n_j \sum_{s=1}^{n_j} \Phi(x_{j,s})$ 表示第 j 类样本映射至第 m 个特征空间中样本的均值。 Φ 表示非线性映射函数。

当第 m 个核函数 K_m 将样本映射至第 m 个特征空间中时,样本类内散度 S_B^m 的迹为

$$\text{tr}(S_B^m) = \text{tr} \left[\sum_{j=1}^k n_j M_j M_j^T - \frac{1}{n} \sum_{q=1}^n \sum_{h=1}^n K_m(x_q, x_h) \right] \quad (6)$$

类间散度 S_W^m 的迹为

$$\text{tr}(S_W^m) = \text{tr} \left[\sum_{j=1}^k \sum_{s=1}^{n_j} (K_m(x_{j,s}, x_{j,s}) - \sum_{j=1}^k n_j M_j M_j^T) \right] \quad (7)$$

对应第 m 个特征空间样本全散度矩阵 S_T^m 的迹为

$$\begin{aligned} \text{tr}(S_T^m) &= \text{tr}(S_B^m) + \text{tr}(S_W^m) = \\ & \text{tr} \left[\sum_{j=1}^k \sum_{s=1}^{n_j} K_m(x_{j,s}, x_{j,s}) - \frac{1}{n} \sum_{q=1}^n \sum_{h=1}^n K_m(x_q, x_h) \right] \end{aligned} \quad (8)$$

结合式(8),经多核函数映射得到的全散度矩阵 S_T 的迹的公式如式(9),其中 d_m 代表核函数的权重,

且 $\sum_{m=1}^M d_m = 1, d_m > 0$:

$$\begin{aligned} \text{tr}(S_T) &= \sum_{m=1}^M d_m \text{tr}(S_T^m) = \text{tr} \left[\sum_{j=1}^k \sum_{s=1}^{n_j} \sum_{m=1}^M d_m K_m(x_{j,s}, x_{j,s}) - \right. \\ & \left. \frac{1}{n} \sum_{q=1}^n \sum_{h=1}^n \sum_{m=1}^M d_m K_m(x_q, x_h) \right] \end{aligned} \quad (9)$$

利用最小化全散度矩阵的迹-间距界来优化基核权重,得到多核 SVM 模型^[15]为

$$\begin{cases} J(d) = \min \frac{1}{2} \sum_{m=1}^M d_m \text{tr}(\mathbf{S}_T^m) \|\mathbf{w}\|^2 + C \sum_i \xi_i \quad \forall i \\ \text{s.t.} \quad \sum_{m=1}^M d_m = 1 \\ y_i (\mathbf{w} \sum_{m=1}^M \sqrt{d_m} \Phi_m(\mathbf{x}_i) + b) \geq 1 - \xi_i \\ d_m \geq 0, \xi_i \geq 0 \end{cases} \quad (10)$$

式中: ξ_i 为松弛变量; C 为惩罚参数。

1) 求解多核 SVM 的最优解

式(10)的拉格朗日方程为

$$\begin{aligned} J = \min \frac{1}{2} \sum_{m=1}^M d_m \text{tr}(\mathbf{S}_T^m) \|\mathbf{w}\|^2 + C \sum_i \xi_i + \\ \sum_i \alpha_i (1 - \xi_i - y_i \mathbf{w} \sum_{m=1}^M \sqrt{d_m} \Phi_m(\mathbf{x}_i) - y_i b) - \sum_i v_i \xi_i \end{aligned} \quad (11)$$

式中: 核函数的权重不变; α_i 、 v_i 为拉格朗日乘子。设:

$$\mathbf{w} = \sqrt{\text{tr}(\mathbf{S}_T)} \mathbf{w} \quad (12)$$

则方程(11)等价于

$$\begin{aligned} J = \min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_i \xi_i + \\ \sum_i \alpha_i (1 - \xi_i - y_i \mathbf{w} \sum_{m=1}^M \frac{\sqrt{d_m}}{\sqrt{\text{tr}(\mathbf{S}_T)}} \Phi_m(\mathbf{x}_i) - y_i b) - \sum_i v_i \xi_i \end{aligned} \quad (13)$$

对 J 关于原变量求极值, 并进一步求解可得

$$\begin{cases} \max_{\alpha} \sum_i \alpha_i - \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j \sum_{m=1}^M \frac{d_m}{\text{tr}(\mathbf{S}_T)} \mathbf{K}_m(\mathbf{x}_i, \mathbf{x}_j) \\ \text{s.t.} \quad 0 \leq \alpha_i \leq C, \sum_i \alpha_i y_i = 0 \quad \forall i \end{cases} \quad (14)$$

进而求得多核 SVM 模型的最优解 α_i^* 。

2) 求解核函数的权重

令 $d_m / \text{tr}(\mathbf{S}_T) = \rho_m$, 则根据式(9), 可推导出

$$\sum_{m=1}^M \rho_m \text{tr}(\mathbf{S}_T^m) = 1 \quad (15)$$

结合式(14)和式(15), 将问题转化为

$$\begin{cases} J(d) = \sum_i \alpha_i^* - \frac{1}{2} \sum_i \sum_j \alpha_i^* \alpha_j^* y_i y_j \sum_{m=1}^M \frac{\rho_m \text{tr}(\mathbf{S}_T^m)}{\text{tr}(\mathbf{S}_T^m)} \mathbf{K}_m(\mathbf{x}_i, \mathbf{x}_j) \\ \text{s.t.} \quad \rho_m \text{tr}(\mathbf{S}_T^m) \geq 0, \sum_{m=1}^M \rho_m \text{tr}(\mathbf{S}_T^m) = 1 \end{cases} \quad (16)$$

由式(16)对 $\rho_m \text{tr}(\mathbf{S}_T^m)$ 求梯度, 可得

$$\frac{\partial J}{\partial(\rho_m \text{tr}(\mathbf{S}_T^m))} = -\frac{1}{2} \sum_i \sum_j \alpha_i^* \alpha_j^* y_i y_j \frac{1}{\text{tr}(\mathbf{S}_T^m)} \mathbf{K}_m(\mathbf{x}_i, \mathbf{x}_j) \quad \forall m \quad (17)$$

为满足 $\rho_m \text{tr}(\mathbf{S}_T^m)$ 上的等式约束和非负性, 梯度

更新方向为

$$D_m = \begin{cases} 0 & \rho_m \text{tr}(\mathbf{S}_T^m) = 0, \frac{\partial J}{\partial(\rho_m \text{tr}(\mathbf{S}_T^m))} - \frac{\partial J}{\partial(\rho_\mu \text{tr}(\mathbf{S}_T^\mu))} > 0 \\ -\frac{\frac{\partial J}{\partial(\rho_m \text{tr}(\mathbf{S}_T^m))}}{\frac{\partial J}{\partial(\rho_\mu \text{tr}(\mathbf{S}_T^\mu))}} & \rho_m \text{tr}(\mathbf{S}_T^m) > 0, m \neq \mu \\ \sum_{v \neq \mu, \rho_v \text{tr}(\mathbf{S}_T^v) > 0} \left[\frac{\frac{\partial J}{\partial(\rho_v \text{tr}(\mathbf{S}_T^v))}}{\frac{\partial J}{\partial(\rho_m \text{tr}(\mathbf{S}_T^m))}} \right] & m = \mu \end{cases} \quad (18)$$

式中, μ 为 $\rho_m \text{tr}(\mathbf{S}_T^m)$ 中具有最大分量的系数, 则 $\rho_m \text{tr}(\mathbf{S}_T^m)$ 的更新方程如式(19)。

$$\rho_m \text{tr}(\mathbf{S}_T^m) \leftarrow \rho_m \text{tr}(\mathbf{S}_T^m) + D_m \gamma \quad (19)$$

式中, γ 为更新步长, 最优步长通过黄金分割法搜索得到。求得最优解 ρ_m^* 后, 根据 $d_m / \text{tr}(\mathbf{S}_T) = \rho_m$,

$\sum_{m=1}^M d_m = 1$, 可求出 d_m^* 。

将 d_m 和 α_i 交替反复迭代, 直到满足停止条件。为满足收敛性, 将 KKT 条件和最大迭代次数作为停止条件。

在满足停止条件后, 求得最优解 α_i^* 、 d_m^* 、 b^* , 进而得到决策函数如式(20)。

$$\text{sgn} \left\{ \sum_{i=1}^n \alpha_i^* y_i \sum_{m=1}^M \frac{d_m^*}{\text{tr}(\mathbf{S}_T^m)} \mathbf{K}_m(\mathbf{x}_i, \mathbf{x}) + b^* \right\} \quad (20)$$

本文提出的混和扰动辨识算法流程如图 1 所示。

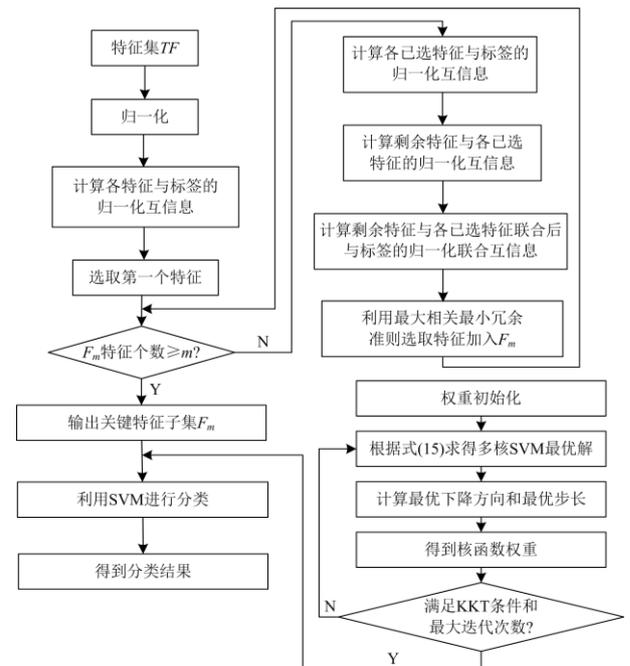


图 1 辨识算法流程图

Fig. 1 Flow chart of the identification algorithm

2 仿真实验

本文根据文献[16-17]生成 8 类典型单一扰动 PQR 信号和 12 种混合扰动。信号采样频率为 3200 Hz。分别采用时域提取、傅里叶变换、短时傅里叶变换、小波变换和 S 变换提取扰动典型特征[16,18-24], 并对其进行归一化处理, 表达式为

$$\frac{E_i - E_{\min}}{E_{\max} - E_{\min}} \quad (21)$$

式中: E_{\max} 、 E_{\min} 分别为原始最大、最小数据; E_i 为待处理数据。

SVM 分别采用多项式核(poly)、指数幂以及高斯径向基(rbf)核函数进行训练。由于扰动类型的数目较多, 多核 SVM 多分类采用一对多的方式实现, 辨识模型采用 5 折交叉验证的方法。

2.1 提取出的混和扰动典型特征

以电压暂降+谐波和闪变+暂态振荡为例[16,25], 利用不同特征提取手段得到时频域下典型特性如图 2、图 3 所示。

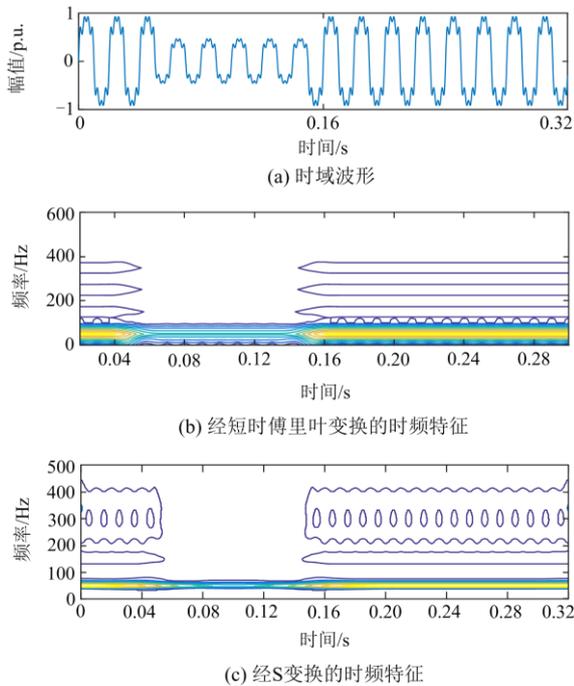
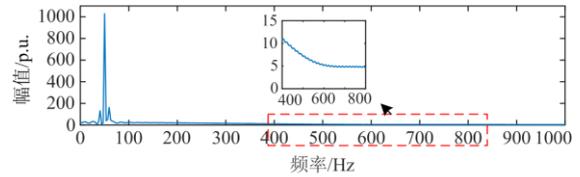
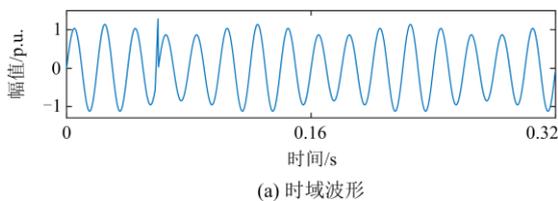
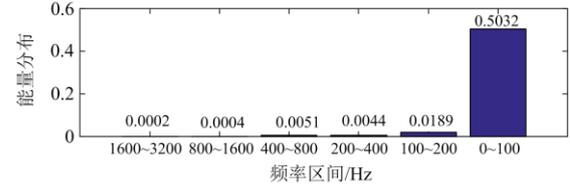


图 2 电压暂降+谐波特性

Fig. 2 Curves of voltage sag plus harmonic characteristic



(b) 经傅里叶变换的时频特征



(c) 经小波变换的时频特性波形

图 3 闪变+暂态振荡特性曲线

Fig. 3 Characteristic curve of flicker plus transient oscillation

1) 由图 2(b)一图 2(c)可知, 在中高频特征频率附近经短时傅里叶变换的时频特征频带较窄, 而在低频特征频率附近 S 变换频带较窄。说明短时傅里叶变换和 S 变换无法在这两种频段内同时实现高分辨率。

2) 由图 3(b)可以看出, 闪变+暂态振荡 500 Hz 的高频分量并没有明显表现, 故利用傅里叶变换对闪变+暂态振荡扰动的识别十分困难。

3) 由图 3(c)可以看出, 利用小波变换不易区分与中高频段相关的复合扰动。

从上述分析可知, 由于各种特征提取手段的局限性, 导致从混和扰动中提取出来的特征间存在边缘重叠问题, 影响混和扰动的辨识。

2.2 基于交互作用下改进 mRAR 算法的选择结果评价

为了说明 1.1 节中算法的性能, 本文按照相关性顺序将前 40 个关键特征平均分成 8 组, 利用 SVM 对 8 组数据进行处理, 得到如图 4 所示的结果。

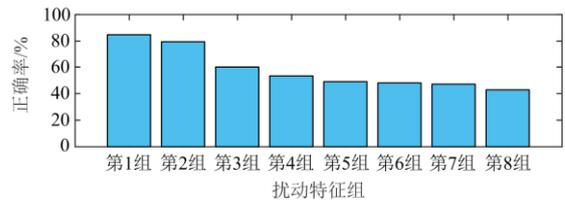


图 4 不同特征组对应的 SVM 辨识结果比较

Fig. 4 Comparison of SVM identification results corresponding to different feature groups

由图 4 可知, 如果特征选取结果排名越靠前, 则 SVM 分类效果越好, 并且在仅输入前 5 个特征时, 分类器的精度便大于 80%。以上表明, 基于交互作用下改进的 mRAR 准则特征选择算法是有效的。

2.3 关键特征子集的构建

按照选择结果的先后逐次增加特征的维数, 所得辨识结果如图 5 所示。

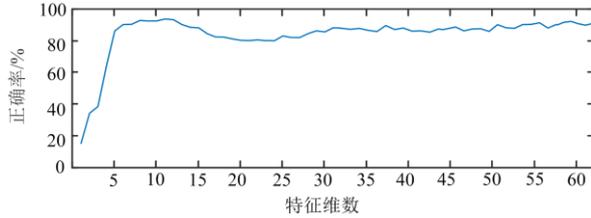


图 5 不同维数下辨识结果

Fig. 5 Identification results in different dimensions

由图 5 可知, 开始时分类器的辨识结果随着维数的增加而增加, 但当维度增加到一定数量时, 辨识结果正确率便逐渐稳定在某一数值附近, 这说明之后添加的特征维数对辨识结果正确率影响不大, 甚至有可能降低正确率。为得到最佳的准确率并减少计算成本, 可选 10 作为 SVM 的维数。

优选出的混合电能质量扰动关键特征子集如表 1 所示。由表 1 可知, 关键特征子集分别来自不同特征提取方法所得的特征, 说明了组合不同来源的特征有利于提高辨识精度。

表 1 关键特征子集

Table 1 Key feature subsets

序号	分析方法	特征
1	stf	幅值标准差的波峰处的频率
2	stf	基频最小值
3	fft	均方根频率
4	stf	主要频率
5	S	基频均值
6	stf	主要频率幅值
7	时域提取	峰值因子
8	stf	基频幅值穿越次数
9	小波变换	小波能量熵
10	stf	高频幅值波峰时间

2.4 核函数的权重分布情况

给出多核 SVM 算法辨识不同混合电能质量扰动时各个基核的权重(仅给出基核权重不全为 0), 如表 2 所示, σ 和 λ 分别为 rbf 核函数和 poly 核函数的核参数。由表 2 可知, 大部分的权重等于 0, 只有少数核函数权重不等于 0。这是因为在训练过程中, 大部分冗余特征被删除, 且只有小部分的有用特征在分类过程中保留下来。同时整个权重的确定过程均自动完成, 避免了人为主观性对辨识精度的影响。

表 2 各基核的权重分布

Table 2 Weight distribution of each base nucleus

扰动类型	rbf $\sigma=1/3$	rbf $\sigma=1/4$	rbf $\sigma=1/5$	rbf $\sigma=1/7$	rbf $\sigma=1$	poly $\lambda=1$
R_1	0	0	0	0	1	0
R_2	0	0	0	0	0	1
R_3	0	0	0	0.447	0	0.553
R_4	0	0	1	0	0	0
R_5	0	0	0	0	0	1
R_6	0	0	1	0	0	0
R_7	0	0	0	0	0	1
R_8	0	0	0	0	0	1
R_9	0.045	0.083	0.132	0.281	0	0.459
R_{10}	0.103	0	0	0	0	0.897
R_{11}	0	1	0	0	0	0
R_{12}	0	0	0	0	1	0

2.5 单核和集成半径信息的多核 SVM 的比较

为说明多核 SVM 的优越性, 给出不同噪声强度下单核 SVM 和多核 SVM 基于关键特征子空间的辨识结果如表 3 所示。由表 3 可知, 与单核 SVM 分类方法相比, 本文提出的算法在噪声影响下的分类精度更高。并且在特征选择后, 不同分类器的精度也有所提高^[25]。本文提出的算法在降低特征计算量和分类器复杂度的同时, 有效提高了分类的正确率。

表 3 单核和多核 SVM 的辨识结果比较

Table 3 Comparison of identification results between single-core SVM and multi-core SVMs

分类器	是否特征选择	SNR ∞	SNR 50 dB	SNR 30 dB	SNR 20 dB
单核	否	93.46%	92.38%	90.25%	88.28%
本文方法	否	96.67%	95.81%	94.63%	93.96%
单核	是	95.68%	94.94%	94.86%	88.28%
本文方法	是	96.83%	96.41%	94.69%	94.15%

SVM 在小样本下具备一定的辨识优势, 多个核函数的组合也有利于有效映射多源数据。图 6 为样本数影响下本文算法的辨识结果。由图 6 可知, 当样本数达到 500 附近时, 算法的辨识正确率便可以基本维持在 80% 以上, 且趋于稳定。

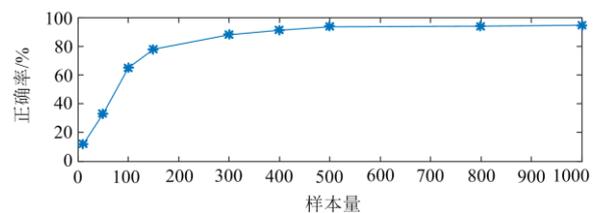


图 6 不同样本量下辨识结果

Fig. 6 Identification results in different sample sizes

2.6 与其他辨识方法的比较

为验证本文辨识算法的有效性,与文献[9-10,12]中的方法进行比较,结果对比如表4所示。仿真模型中,文献[9]的高频和低频窗宽系数分别设为0.15、10,文献[10]的高频和低频窗宽系数分别设为0.2、5,文献[12]采用对应的分层分类结构。

表4 分类器结果对比

Table 4 Comparison of classifier results

分类器	SNR	SNR	SNR	SNR
	∞	50 dB	30 dB	20 dB
本文方法	96.83%	96.41%	94.69%	94.15%
文献[9]	95.43%	95.29%	94.31%	92.85%
文献[10]	95.32%	95.14%	94.22%	93.02%
文献[12]	95.01%	94.36%	94.69%	91.60%

由表4可知,在不同的噪声环境下,本文所提出方法的分类准确率均较高,表明该方法具有较强的分类能力和抗干扰能力。

3 结论

为降低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,在筛选时频域特征中关键特征子集的基础上,加以集成半径信息的多核SVM实现准确辨识,结论如下:

1) 提出了一种基于交互作用下改进 mRAR 的特征选择算法,有效去除了冗余信息,提高了分类器的运算速度,保证了在特征数较少时有较高的识别精度。

2) 通过比较不同核函数的权重分布以及单核和集成半径信息的多核 SVM 的辨识结果,表明集成半径信息的多核 SVM 算法不仅避免了基核个数和参数选取的主观性,同时更全面、切实地描述了不同来源的特征。

3) 通过对噪声和样本数影响下的辨识结果进行分析,验证了所提出的算法受噪声、扰动间干扰及样本数的影响较小。

参考文献

- [1] 王燕. 电能质量扰动检测的研究综述[J]. 电力系统保护与控制, 2021, 49(13): 174-186.
WANG Yan. Review of research development in power quality disturbance detection[J]. Power System Protection and Control, 2021, 49(13): 174-186.
- [2] 冯丹丹, 王同勋. 数据驱动的电能质量扰动特征建模方法[J]. 供用电, 2020, 37(9): 23-28.
FENG Dandan, WANG Tongxun. Data-driven power quality disturbance characteristics modeling method[J]. Distribution & Utilization, 2020, 37(9): 23-28.
- [3] 张殷, 武利会, 范心明, 等. 基于改进 S 变换和 GA-SVM 的电能质量扰动识别与分类[J]. 广东电力, 2021, 34(5): 99-106.
ZHANG Yin, WU Lihui, FAN Xinming, et al. Identification and classification of power quality disturbances based on modified S transform and GA-SVM[J]. Guangdong Electric Power, 2021, 34(5): 99-106.
- [4] 覃思师, 刘前进. 基于 STFT 变换和 DAGSVMs 的电能质量扰动识别[J]. 电力系统保护与控制, 2011, 39(1): 83-86.
QIN Sishi, LIU Qianjin. Power quality disturbances detection and identification based on STFT transform and DAGSVMs[J]. Power System Protection and Control, 2011, 39(1): 83-86.
- [5] 姚建刚, 郭知非, 陈锦攀. 基于小波和 BP 神经网络的电能扰动分类新方法[J]. 电网技术, 2012, 36(5): 139-144.
YAO Jiangan, GUO Zhifei, CHEN Jinpan. A new approach to recognize power quality disturbances based on wavelet transform and BP neural network[J]. Power System Technology, 2012, 36(5): 139-144.
- [6] 吴兆刚, 李唐兵, 姚建刚, 等. 基于小波和改进神经树的电能质量扰动分类[J]. 电力系统保护与控制, 2014, 42(24): 86-92.
WU Zhaogang, LI Tangbing, YAO Jiangan, et al. Power quality disturbance classification based on a wavelet and improved neural tree[J]. Power System Protection and Control, 2014, 42(24): 86-92.
- [7] 黄南天, 张卫辉, 蔡国伟, 等. 采用改进多分辨率快速 S 变换的电能质量扰动识别[J]. 电网技术, 2015, 39(5): 1412-1418.
HUANG Nantian, ZHANG Weihui, CAI Guowei, et al. Power quality disturbances classification with improved multiresolution fast S-transform[J]. Power System Technology, 2015, 39(5): 1412-1418.
- [8] 尹志勇, 陈永光, 刘金宁, 等. 装备电力系统电能质量复合扰动识别方法研究[J]. 高压电器, 2017, 53(12): 195-201.
YIN Zhiyong, CHEN Yongguang, LIU Jinning, et al. Complex disturbances classification of equipment power quality[J]. High Voltage Apparatus, 2017, 53(12): 195-201.
- [9] 杨剑锋, 姜爽, 石戈戈. 基于分段改进 S 变换的复合电能质量扰动识别[J]. 电力系统保护与控制, 2019, 47(9): 64-71.
YANG Jianfeng, JIANG Shuang, SHI Gege. Classification of composite power quality disturbances based on piecewise-modified S transform[J]. Power System Protection and Control, 2019, 47(9): 64-71.
- [10] 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.
- [11] 王仁明, 汪宏阳, 张赟宁, 等. 基于分段改进 S 变换和随机森林的复合电能质量扰动识别方法[J]. 电力系统保护与控制, 2020, 48(7): 19-28.
- WANG Renming, WANG Hongyang, ZHANG Yunning, et al. Composite power quality disturbance recognition based on segmented modified S-transform and random forest[J]. Power System Protection and Control, 2020, 48(7): 19-28.
- [12] 汪洋, 肖先勇, 刘阳, 等. 短时电能质量复合扰动分类特征选取与马氏距离分类法[J]. 电网技术, 2014, 38(4): 1064-1069.
- WANG Yang, XIAO Xianyong, LIU Yang, et al. Classifying features selection and classification based on Mahalanobis distance for complex short time power quality disturbances[J]. Power System Technology, 2014, 38(4): 1064-1069.
- [13] JAKULIN A. Attribute interactions in machine learning [D]. Ljubljana: University of Ljubljana, 2003.
- [14] PRESS W, FLANNERY B, TEUKOLSKY S, et al. Numerical recipes in C: the art of scientific computing[J]. Cambridge: Cambridge University Press, 1998.
- [15] SONNENBURG S, RÄTSCH G, SCHÄFER C, et al. Large scale multiple kernel learning[J]. Journal of Machine Learning Research, 2006, 7(2): 1531-1565.
- [16] 黄南天, 徐殿国, 刘晓胜. 基于 S 变换与 SVM 的电能质量复合扰动识别[J]. 电工技术学报, 2011, 26(10): 23-30.
- HUANG Nantian, XU Dianguo, LIU Xiaosheng. Identification of power quality complex disturbances based on S-transform and SVM[J]. Transactions of China Electrotechnical Society, 2011, 26(10): 23-30.
- [17] YOUSSEF A M, ABDEL-GALIL T K, EL-SAADANY E F, et al. Disturbance classification utilizing dynamic time warping classifier[J]. IEEE Transactions on Power Delivery, 2004, 19(1): 272-278.
- [18] 徐永海, 赵燕. 基于短时傅里叶变换的电能质量扰动识别与采用奇异值分解的扰动时间定位[J]. 电网技术, 2011, 35(8): 174-180.
- XU Yonghai, ZHAO Yan. Identification of power quality disturbance based on short-term fourier transform and disturbance time orientation by singular value decomposition[J]. Power System Technology, 2011, 35(8): 174-180.
- [19] 陈晓光. 基于小波变换与傅立叶分析的谐波检测方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2009.
- CHEN Xiaoguang. Research on harmonic detection methods based on wavelet transform and Fourier transform[D]. Harbin: Harbin Institute of Technology, 2009.
- [20] 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.
- [21] 吴建章, 梅飞, 陈畅, 等. 基于经验小波变换的电力系统谐波检测方法[J]. 电力系统保护与控制, 2020, 48(6): 136-143.
- WU Jianzhang, MEI Fei, CHEN Chang, et al. Harmonic detection method in power system based on empirical wavelet transform[J]. Power System Protection and Control, 2020, 48(6): 136-143.
- [22] ZHAO Wenjing, SHANG Liqun, SUN Jinfan. Power quality disturbance classification based on time-frequency domain multi-feature and decision tree[J]. Protection and Control of Modern Power Systems, 2019, 4(4): 337-342.
- [23] KANITPANYACHAROEAN W, PREMRUDEEPREEC-HACHARN S. Power quality problem classification using wavelet transformation and artificial neural networks[C] // IEEE PES Power Systems Conference and Exposition, October 10-13, 2004, New York, NY, USA: 1185-1190.
- [24] 陈永延. 电力系统电能质量扰动识别方法研究[D]. 杭州: 浙江大学, 2010.
- CHEN Yongyan. Research on classification of power quality disturbances[D]. Hangzhou: Zhejiang University, 2010.
- [25] 黄南天, 彭华, 蔡国伟, 等. 电能质量复合扰动特征选择与最优决策树构建[J]. 中国电机工程学报, 2017, 37(3): 776-786.
- HUANG Nantian, PENG Hua, CAI Guowei, et al. Feature selection and optimal decision tree construction of complex power quality disturbances[J]. Proceedings of the CSEE, 2017, 37(3): 776-786.

收稿日期: 2021-10-11; 修回日期: 2021-11-25

作者简介:

张明龙(1976—), 男, 硕士, 高级工程师, 研究方向为电力系统及其自动化; E-mail: 10446170@qq.com

朱珂(1977—), 男, 通信作者, 副教授, 硕士生导师, 主要研究方向为状态监测, 电能质量。E-mail: zhuke@sdu.edu.com

(编辑 魏小丽)