

基于 SVM 的电能质量扰动信号分类方法

郭云峰 杨晓梅

(四川大学电气工程学院 四川 成都 610065)

摘要 针对电能质量扰动信号分类中存在波形相似、准确率低的问题,提出一种双层支持向量机的分类方法。利用可调 Q 因子小波变换(tunable Q-factor wavelet transform, TQWT)对信号进行 5 层分解并提取特征,使用经粒子群算法优化后的支持向量机对扰动信号进行第一次分类;对第一次分类中错误样本集中的类别,结合小波去噪算法和 TQWT 提取特征;使用优化后的支持向量机对扰动信号进行第二次分类,以提高信号的分类准确率。仿真数据实验表明,所提出的分类方法能够有效识别 14 类扰动,与其他分类方法相比分类准确率更高,抗噪性更强,具有一定的应用价值。

关键词 支持向量机 电能质量 可调 Q 因子小波变换 特征提取 扰动分类

中图分类号 TP391

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2022.07.015

POWER QUALITY DISTURBANCE SIGNAL CLASSIFICATION METHOD BASED ON SVM

Guo Yunfeng Yang Xiaomei

(College of Electrical Engineering, Sichuan University, Chengdu 610065, Sichuan, China)

Abstract In order to solve the problem of waveform similarity and low accuracy in power quality disturbance signal classification, we propose a two-layer support vector machine (SVM). We used tunable Q-factor wavelet transform (TQWT) to decompose the signal into five layers and extract the features. We adopted SVM which was optimized by particle swarm optimization algorithm to classify the disturbance signal for the first time. For the categories in the error sample set in the first classification, we combined wavelet denoising algorithm with TQWT to extract features, and used the optimized support vector machine to classify the disturbance signal for the second time, so as to improve the classification accuracy of the signal. Simulation data show that the proposed method can effectively identify 14 types of disturbances, and compared with other classification methods, it has higher classification accuracy, stronger noise resistance and has certain application value.

Keywords Support vector machines (SVM) Power quality Tunable Q-factor wavelet transform Feature extraction Disturbance classification

0 引言

提供可靠、优质的电力已成为现代电力行业主要的发展目标之一。电能质量扰动主要包括干扰设备正常运行的电压、电流或基频的偏差,如果未得到及时处理,可能会造成重大的损失。为改善供电质量,需要对扰动信号进行更智能的分类识别,以采取合理的措施来预防扰动事件的发生。

多数电能质量扰动为非平稳信号,常采用不同的特征提取与分类器相结合的方法来解决电能质量扰动分类问题。特征提取的主要方法有:S 变换(S transform, ST)^[1-2]、离散小波变换(discrete wavelet transform, DWT)^[3-4]、短时傅里叶变换(short-time Fourier transform, STFT)^[5]以及希尔伯特-黄变换(Hilbert-huang transform, HHT)^[6]等。使用的分类器主要有:支持向量机(support vector machine, SVM)^[7]、人工神经网络(artificial neural network, ANN)^[8]及决策树^[9-10]

等。其中 ANN 虽然分类效果较好,但是计算量较大,耗费时间较多;决策树算法简单,但受噪声影响较大,鲁棒性不强,分类效果欠佳。SVM 具有较强的自适应学习能力,使用核函数可以解决非线性样本的分类问题。在样本类型较少且分类特征选择适当时,SVM 分类效果较好;但当样本类型较多时,部分扰动信号的波形相似,使得单一 SVM 分类准确率较低。

针对单一 SVM 分类准确率较低的缺点,本文提出了双层 SVM 的分类方法,该分类方法采用两层 SVM 组成分类器。首先利用 TQWT 对扰动信号进行 5 层分解并提取特征,使用经粒子群算法优化后的 SVM 进行第一次分类,然后根据分类结果,结合小波去噪算法和 TQWT 提取特征,使用优化后的 SVM 对分类准确率较低的部分类别信号进行第二次分类,以达到提高分类准确率的效果,并通过仿真实验验证了所提方法的有效性。

1 支持向量机的分类原理

SVM 算法^[11]采用结构风险最小化原理,具有良好的泛化能力,通过构造超平面对样本进行分类,基本思想如图 1 的样本二分类情况所示。




图 1 最优超平面

图 1 中,“+”和“-”分别代表不同训练样本, D 为最优分类面,边界 D_1 和 D_2 是根据两类样本离 D 最近的点确定的。

设训练样本为 $(x_i, y_i), i = 1, 2, \dots, n, x_i \in \mathbf{R}^d$ 为样本数据, $y_i \in \{+1, -1\}$ 为样本标签, n 是样本数量, d 是输入维数。当训练样本如图 1 线性可分时,最优分类超平面为:

$$wx + b = 0 \quad (1)$$

式中: w 为权值法向量, b 为偏置项。分类间隔为 $2/\|w\|$, 要使分类间隔最大, 即求解 $\|w\|$ 最小值, 等效为以下约束性优化问题的求解:

$$\min \frac{1}{2} \|w\|^2 \quad \text{s. t. } y_i(wx_i + b) - 1 \geq 0 \quad (2)$$

一般而言, 样本为线性不可分的, 此时使用松弛变量 $\xi_i \geq 0$ 将优化问题转变为:

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (3)$$

$$\text{s. t. } y_i(wx_i + b) \geq 1 - \xi_i$$

式中: C 为正正则化常数。在式(3)使用拉格朗日乘子法求得最优决策函数为:

$$f(x) = \text{sgn}\left(\sum_{i=1}^n y_i \alpha_i (wx_i + b)\right) \quad (4)$$

式中: α 是拉格朗日系数。根据 K-T 条件, 上述优化问题的解满足如下约束条件:

$$\alpha_i [y_i(wx_i + b) - 1] = 0 \quad (5)$$

为处理非线性分类问题, 通常 SVM 使用核函数 $K(x_i, x_j)$ 将样本从原空间映射到高维特征空间。常用的核函数有线性核、多项式核和高斯核等, 本文采用的是高斯核函数。依照 Mercer 条件, 引入核函数之后的最优决策函数为:

$$f(x) = \text{sgn}\left(\sum_{i=1}^n y_i \alpha_i K(x, x_i) + b\right) \quad (6)$$

SVM 最初是针对二分类问题提出的, 在处理多分类问题时, 需要将多分类问题转化成二分类问题处理。目前对于处理多分类问题的常见算法有: 一对一和一对多算法。本文使用的 SVM 采用的是一对一算法^[12], 下面简单介绍一下该算法的基本原理。

设有 k 类数据, 其主要思想是构建 $k(k-1)/2$ 分类器, 其中每个分类器都使用来自两个类的数据进行训练。选择第 i 类数据和第 j 类数据构造一个分类器, 解决式(7)所示的二分类问题。

$$\min \frac{1}{2} (w^{ij})^T w^{ij} + C \sum \xi^{ij} (w^{ij})^T \quad (7)$$

式(7)满足如下约束条件:

$$\begin{cases} y(w^{ij}x + b^{ij}) \geq 1 - \xi^{ij} & y_i = i \\ y(w^{ij}x + b^{ij}) \leq -1 + \xi^{ij} & y_i \neq i \end{cases} \quad (8)$$

然后采用投票法解决上述问题。若判断 x 属于第 i 类, 则第 i 类票数加 1; 若判断 x 属于第 j 类, 则第 j 类票数加 1。最后 x 属于票数最多的类。

2 TQWT 原理及特征提取

2.1 TQWT 基本原理

TQWT 是一种强有力的分解方法,具有广泛的应用领域,其是传统的单 Q 因子小波变换的改进^[13]。TQWT 与离散小波变换类似,采用双通道多速率滤波器组,具有低通滤波器和高通滤波器。主要有三个参数: Q 因子、过采样率 R 和分解层数 J 。

输入信号 $Sig[m]$ 在每一层被分解为低通子带 ($Lsig$) 和高通子带 ($Hsig$), 采样率分别为 αf_s 和 βf_s (α 和 β 分别是低通和高通缩放因子, f_s 是输入信号的采样率)。低通子带和高通子带由低通滤波器 $h_0(w)$ 和高通滤波器 $h_1(w)$ 得到, 高通子带在下一层分解中被进一步分解为低通子带和高通子带, 如图 2




图 2 TQWT 分解信号过程

2.2 扰动信号特征提取

本文根据 IEEE Std^[14] 建立 7 种单一电能质量扰动数学模型, 分别为电压暂降 (C1)、电压暂升 (C2)、电压中断 (C3)、谐波 (C4)、暂态振荡 (C5)、暂态脉冲 (C6) 和电压闪变 (C7)。在此基础上生成 7 种复合电能质量扰动信号, 分别为谐波 + 脉冲 (C8)、谐波 + 振荡 (C9)、谐波 + 闪变 (C10)、暂降 + 脉冲 (C11)、谐波 + 暂升 (C12)、谐波 + 暂降 + 脉冲 (C13)、谐波 + 暂降 + 振荡 (C14)。扰动信号的基波频率为 50 Hz, 采样频率为 6.4 kHz, 信号长度为 1 280。在 TQWT 的参数设置中, R 参考文献 [15] 设置为 3, 根据实验分析设置 Q 为 1.1, 对信号进行 5 层 TQWT 分解, 利用小波系数进行重构得到信号在各尺度上的重构信号。本文考虑了峰峰值、均方根值、均值、相对模式能量比、瞬时幅值、信息熵、峰值因数、峭度、希尔伯特变换^[4]后的包络幅值、熵范数、频谱最大值和最小值共 12 个特征, 根据实验分析, 选择了分类效果最好的峰值 (F_1)、均方根值 (F_2)、峭度 (F_3)、频谱最大值 (F_4) 和希尔伯特变换后的包络幅值 (F_5) 共 5 个特征, 对 6 层重构信号求取这 5 个特征值, 每个信号构成一个 30 维的特征。峭度的计算式为:

所示。 $h_0(w)$ 和 $h_1(w)$ 计算公式如式 (9) 和式 (10) 所示。

$$h_1(w) = \begin{cases} 0 & |w| \leq (1-\beta)\pi \\ \theta\left(\frac{\alpha\pi-w}{a+\beta-1}\right) & (1-\beta)\pi < |w| < \alpha\pi \\ 1 & \alpha\pi \leq |w| \leq \pi \end{cases} \quad (9)$$

$$h_0(w) = \begin{cases} 1 & |w| \leq (1-\beta)\pi \\ \theta\left(\frac{w+(\beta-1)\pi}{a+\beta-1}\right) & (1-\beta)\pi < |w| < \alpha\pi \\ 0 & \alpha\pi \leq |w| \leq \pi \end{cases} \quad (10)$$

式中: $\theta(w)$ 为具二阶消失矩的 Daubechies 规范正交基。TQWT 中的参数 Q 、 R 、 J 与 α 和 β 的关系如式 (11) 所示。

$$\begin{cases} Q = (\beta - 2) / \beta \\ R = \beta / (a - 1) \end{cases} \quad (11)$$

$$F_3 = \frac{1}{N \times \sigma^4} \sum_{j=1}^N (C_{ij} - s)^4 \quad (12)$$

式中: C_{ij} 为 i 层上重构信号的第 j 个数值, N 为信号长度, σ 和 s 为 C_{ij} 的标准差和均值。

包络幅值的计算式为:

$$F_5 = \sum_{j=1}^N h_{ij}^2 \quad (13)$$

式中: h_{ij} 为 C_{ij} 经希尔伯特变换后的模值。

3 仿真分析

3.1 分类实验

根据数学模型通过 MATLAB 2016 分别生成信噪比为 20 dB、30 dB、40 dB 的 14 类电能质量扰动信号, 每类 300 个样本, 随机选取其中 200 个作为训练样本, 100 个作为测试样本, 分别进行 5 层 TQWT 分解提取特征, 其中信噪比为 30 dB 的 C1、C9 和 C14 扰动信号的 TQWT 分解如图 3 所示。本文所使用的分类器模型如图 4 所示, 第一层 SVM 对信号进行第一次分类, 第二层 SVM 对错误样本集中的类别进行第二次分类。

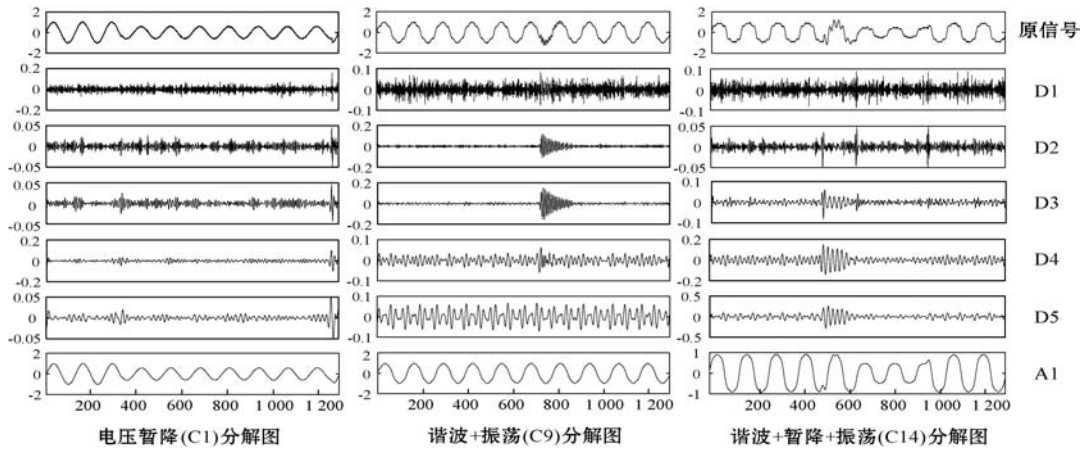


图3 不同扰动信号 TQWT 分解

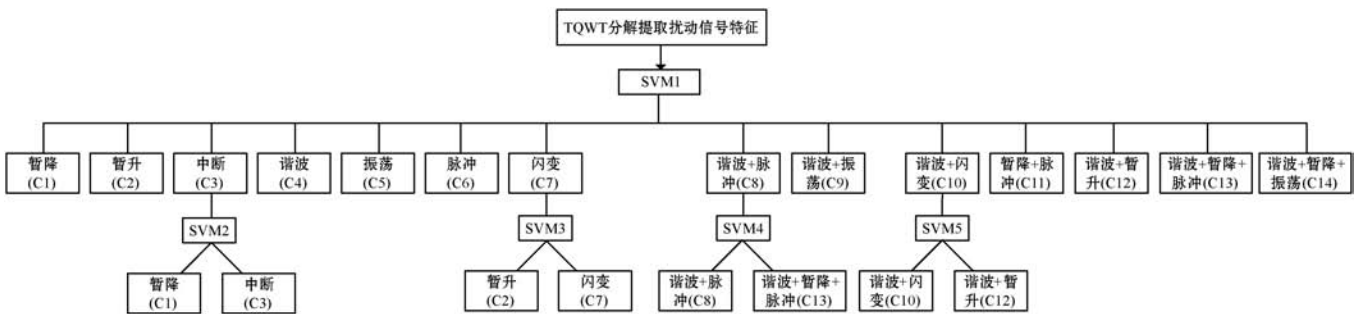



图4 分类器模型

SVM 中惩罚参数 C 和高斯核参数 g 的正确选取, 是扰动信号能否被正确分类的关键。本文使用信噪比为 20 dB 的样本通过粒子群算法^[16]对 SVM 进行参数寻优, 设定惩罚参数 $C \in [0.1, 1\ 000]$, 高斯核参数 $g \in [0.01, 10]$, 最大进化代数为 50, 种群数量为 20, 参数局部和全局搜索能力初始值 c_1 和 c_2 均取为 2, 惯性权重 k 为 0.6, 采用准确率适应度函数作评价指标。寻优得到最优参数 $C = 650.870\ 4$, $g = 0.085\ 587$, 分类器模型中的所有 SVM 的高斯核参数和惩罚因子均取相同值。


以含 20 dB 噪声的样本为例, 说明本文提出的分类方法的运作过程。经过第一次分类后, 得知暂降 (C1) 和中断 (C3)、暂升 (C2) 和闪变 (C7)、谐波 + 脉冲 (C8) 和 谐波 + 暂降 + 脉冲 (C13), 以及谐波 + 闪变 (C10) 和 谐波 + 暂升 (C12) 信号容易分类混淆。对于第一次 SVM 分类之后判定为闪变 (C7) 的样本, 用 TQWT 对暂升 (C2) 和闪变 (C7) 的训练样本进行 5 层分解提取特征训练 SVM, 再将第一次分类判定为闪变 (C7) 的样本作为测试集进行第二次分类。对于第一次分类之后判定为谐波 + 闪变 (C10) 的样本处理过程相同。

对于第一次分类判定为中断 (C3) 的样本, 因为部分暂降信号的暂降部分波形接近于中断, 且噪声覆盖了信号的特征, 直接使用 TQWT 分解提取特征进行第二次分类并不能取得较好的效果。本文用小波去噪算法^[17]对暂降 (C1) 和中断 (C3) 的训练样本进行滤波, 滤波后信号幅值在 -1 到 1 之间, 将 -1 到 1 以 0.1 为

单位分为 20 个子区间, 计算每个子区间内的采样点数, 如图 5 所示, 再将每个子区间内的采样点数除以总采样点数 1 280, 最后每个信号得到一个 20 维的特征, 以此训练 SVM 再进行分类^[18]。



(a) 电压暂降(C1)



(b) 电压中断(C3)

图5 统计单位采样点数

对于第一次分类判定为谐波 + 脉冲 (C8) 的样本,采用小波去噪算法对谐波 + 脉冲 (C8) 和谐波 + 暂降 + 脉冲 (C13) 的训练样本进行滤波,经 TQWT 分解之后提取特征训练 SVM,将第一次分类

判定为谐波 + 脉冲 (C8) 的样本作为测试集,得到第二次分类的结果。在信噪比为 20 dB 时,单层 SVM 和双层 SVM 部分类别的混淆矩阵如表 1 和表 2 所示。

表 1 单层 SVM 的混淆矩阵

扰动类型	分类结果/个													
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14
C1	91	0	9	0	0	0	0	0	0	0	0	0	0	0
C2	0	92	0	0	0	0	8	0	0	0	0	0	0	0
C3	1	0	99	0	0	0	0	0	0	0	0	0	0	0
C7	0	0	0	0	0	0	100	0	0	0	0	0	0	0
C8	0	0	0	0	0	0	0	100	0	0	0	0	0	0
C10	0	0	0	2	0	0	0	0	0	96	0	2	0	0
C12	0	0	0	0	0	0	0	0	0	5	0	95	0	0
C13	0	0	0	0	0	0	0	4	0	0	3	0	93	0

表 2 双层 SVM 的混淆矩阵

扰动类型	分类结果/个													
	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14
C1	98	0	2	0	0	0	0	0	0	0	0	0	0	0
C2	0	100	0	0	0	0	0	0	0	0	0	0	0	0
C3	1	0	99	0	0	0	0	0	0	0	0	0	0	0
C7	0	0	0	0	0	0	100	0	0	0	0	0	0	0
C8	0	0	0	0	0	0	0	100	0	0	0	0	0	0
C10	0	0	0	2	0	0	0	0	0	96	0	2	0	0
C12	0	0	0	0	0	0	0	0	0	3	0	97	0	0
C13	0	0	0	0	0	0	0	3	0	0	3	0	94	0

本文使用单层 SVM 和双层 SVM 分别对不同信噪比的信号进行了分类,结果如表 3 和表 4 所示。由表 3 和表 4 可知,信噪比为 20 dB 时,双层 SVM 分类准确率比单层 SVM 分类准确率高了 1.29%,在 30 dB 和 40 dB 情况下分别高出 1.5% 和 1.07%,由此证明了所提方法的有效性。

表 3 不同噪声强度下单层 SVM 的分类结果

扰动类型	分类准确率/%			
	40 dB	30 dB	20 dB	
单一扰动	C1	90.00	92.00	91.00
	C2	99.00	95.00	92.00
	C3	99.00	100.00	99.00
	C4	100.00	100.00	99.00
	C5	100.00	100.00	99.00
	C6	100.00	100.00	100.00
	C7	100.00	100.00	100.00

续表 3

扰动类型	分类准确率/%			
	40 dB	30 dB	20 dB	
双重扰动	C8	100.00	99.00	100.00
	C9	99.00	96.00	92.00
	C10	100.00	98.00	96.00
	C11	97.00	98.00	95.00
三重扰动	C12	95.00	93.00	95.00
	C13	93.00	93.00	93.00
	C14	100.00	100.00	100.00
平均准确率/%		98.00	97.43	96.50

表 4 不同噪声强度下双层 SVM 的分类结果

扰动类型	分类准确率/%			
	40 dB	30 dB	20 dB	
单一扰动	C1	99.00	99.00	98.00
	C2	100.00	100.00	100.00

续表 4

扰动类型	分类准确率/%			
	40 dB	30 dB	20 dB	
单一扰动	C3	99.00	100.00	99.00
	C4	100.00	100.00	99.00
	C5	100.00	100.00	99.00
	C6	100.00	100.00	100.00
	C7	100.00	100.00	100.00
双重扰动	C8	100.00	99.00	100.00
	C9	99.00	96.00	92.00
	C10	100.00	98.00	96.00
	C11	97.00	98.00	95.00
	C12	97.00	99.00	97.00
三重扰动	C13	96.00	96.00	94.00
	C14	100.00	100.00	100.00
平均准确率/%		99.07	98.93	97.79

3.2 对比实验

为了进一步验证本文特征提取方法和分类器构造方法的合理性,本文使用 TQWT 对信号进行 5 层分解并提取特征,以 BP 神经网络和随机森林(random forest, RF)作为分类器,对比分类效果,结果如表 5 所示。由表 5 可知,在不同噪声背景下,本文所提出的分类方法准确率均高于其他两种分类器,体现了本文所提出方法的优越性。

表 5 分类结果对比

分类器	分类准确率/%		
	40 dB	30 dB	20 dB
本文	99.07	98.93	97.79
TQWT + BP	97.71	96.40	94.31
TQWT + RF	96.00	95.36	94.07

4 结 语

为了解决单一 SVM 分类准确率较低的问题,本文提出了一种双层 SVM 的电能质量信号分类模型。主要工作如下:

(1) 首先采用 TQWT 对信号进行 5 层分解并提取特征,使用 SVM 进行第一次分类。

(2) 根据第一次分类得到的结果,结合小波去噪算法和 TQWT 提取信号特征,针对错误样本集中的类别进行第二次分类。

相对于单层 SVM,双层 SVM 能够对错误分类的信号进行二次分类,提高了信号的分类准确率。通过对 14 种单一和复合扰动的分类实验证明了该方法具有分类准确率高、抗噪能力强的优点,具有较高的实用价值。

通过实验表明本文仍有较大的改进空间,例如在使用 SVM 对信号进行第一次分类之后,部分谐波 + 振荡(C9)信号被判定为谐波(C4)信号,因为每个信号样本振荡部分的幅度不同,且噪声覆盖了信号的振荡特征,导致振荡幅度较小的信号被错误分类,目前通过二次分类也不能得到满意的结果。此外,在对各类信号进行第二次分类时也未完全正确分类,因此未来工作需要查阅更多的文献,研究能更好地提取信号特征的方法,实现信号进行二分类时准确分类。

参 考 文 献

- [1] Salem M E, Mohamed A, Samad S A. Rule based system for power quality disturbance classification incorporating S-transform features [J]. Expert Systems with Applications, 2010, 37(4): 3229 - 3235.
- [2] 曾晓青,陈永刚,张睿兴. 广义 S 变换在移频信号检测中的应用[J]. 计算机应用与软件, 2013, 30(4): 29 - 32.
- [3] Chandrasekar P, Kamaraj V. Detection and classification of power quality disturbance waveform using MRA based modified wavelet transform and neural networks[J]. Journal of Electrical Engineering, 2010, 61(4): 235 - 240.
- [4] 李四海,满自斌,张红. 基于小波变换和 SVM 的心电早博信号识别[J]. 计算机应用与软件, 2014, 31(8): 182 - 185.
- [5] 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.
- [6] 李云天,赵妍,李楠,等. 基于 HHT 的电能质量检测新方法[J]. 中国电机工程学报, 2005, 25(17): 52 - 56.
- [7] Yongd D, Bhowmik S, Magnago F. An effective power quality classifier using wavelet transform and support vector machines[J]. Expert Systems with Applications, 2015, 15(1): 6075 - 6081.
- [8] Mishra S, Bhende C N, Panigrahi B K. Detection and classification of power quality disturbances using S-transform and probabilistic neural network[J]. IEEE Transactions on Power Delivery, 2008, 23(1): 280 - 287.
- [9] Zhao F Z, Yang R G. Power-quality disturbance recognition using S-transform[J]. IEEE Trans on Power Delivery, 2007, 22(2): 944 - 950.

从图2、图3中可以发现,所提最优准则的图形呈锯齿状,这是由于在式(10)中 $n \approx \left\lceil \frac{\rho + K\alpha}{\beta + \alpha} \right\rceil$,即认知用户数门限取值是离散的。

4 结 语

认知无线电是5G网络关键技术之一。本文分析采用能量检测法进行协作频谱感知的优化方法,分析一种在不影响主用户通信的前提下,最优化代价函数的算法。并将这种算法引申开来,提出在保证主用户PU正常通信和满足代价函数边界条件下,寻找最小协作认知用户数的算法。通过仿真发现这种算法既保证了主用户的正常通信,又减少了所需的协作认知用户数,改善了漏检率性能,通过最优化,代价函数值大大降低,优化效果明显。

参 考 文 献

- [1] 李芃芃,郑娜,仇沛川,等. 全球5G频谱研究概述及启迪[J]. 电讯技术,2017,57(6):734-740.
 - [2] 闫玉芝,李有明,周桂莉,等. 基于加权一致优化的宽带分布式协作压缩频谱感知算法[J]. 电信科学,2016,32(11):71-76.
 - [3] 张键,朱琦. OFDM认知无线电系统中的自适应资源分配新算法[J]. 系统仿真学报,2012,24(12):2535-2539.
 - [4] Sharma S K, Lagunas E, Chatzinotas S, et al. Application of compressive sensing in cognitive radio communications: A survey[J]. IEEE Communications Surveys & Tutorials,2016,18(3):1838-1860.
 - [5] Chen L, Zhao N, Chen Y F, et al. Over-the-air computation for cooperative wideband spectrum sensing and performance analysis[J]. IEEE Transactions on Vehicular Technology, 2018,67(11):10603-10614.
 - [6] Sharma G, Sharma R. Cluster-based distributed cooperative spectrum sensing over Nakagami fading using diversity reception[J]. IET Networks,2019,8(3):211-217.
 - [7] Sharma G, Sharma R. Energy efficient collaborative spectrum sensing with clustering of secondary users in cognitive radio networks[J]. IET Communications, 2019, 13(8): 1101-1109.
 - [8] Abdelmosen A, Wala H. Advances on spectrum sensing for cognitive radio networks: Theory and applications[J]. IEEE Communications Surveys & Tutorials, 2017,19(2):1277-1304.
 - [9] Qin Z J, Gao Y, Plumbley M D. Wideband spectrum sensing on real-time signals at sub-Nyquist sampling rates in single and cooperative multiple nodes[J]. IEEE Transactions on Signal Processing, 2016, 64(12):3106-3117.
 - [10] 顾晓伟. 认知无线电中频谱感知技术的研究[D]. 镇江: 江苏科技大学,2019.
 - [11] Ma Y, Gao Y, Liang Y C, et al. Reliable and efficient sub-Nyquist wideband spectrum sensing in cooperative cognitive radio networks[J]. IEEE Journal on Selected Areas in Communications,2016,34(10):2750-2762.
 - [12] Alexander L P, Jamime V M. Cooperative wideband spectrum sensing based on sub-Nyquist sparse fast Fourier transform[J]. IEEE Transactions on Circuits and Systems II: Express Briefs,2016,63(1):39-43.
 - [13] 闫盛楠,刘洛辛. 基于支撑集融合的分布式协作压缩频谱检测方法[J]. 系统工程与电子技术,2020,42(2):466-472.
- ~~~~~
- (上接第100页)
- [10] 于燕平,林涛. 基于分形特征提取的电能质量数据挖掘[J]. 计算机应用与软件,2016,33(11):24-27,65.
 - [11] Burges C J. A tutorial on support vector machines for pattern recognition[J]. Data Mining and Knowledge Discovery, 1998, 2(2): 121-167.
 - [12] Yong D D, Bhowmik S, Magnago F. An effective power quality classifier using wavelet transform and support vector machine[J]. Expert Systems with Applications, 2015, 42(15/16):6075-6081.
 - [13] Aydiner E, Tuncer T, Dogan S. A Tunable-Q wavelet transform and quadruple symmetric pattern based EEG signal classification method[J]. Medical Hypotheses, 2020, 134(1):16-22.
 - [14] Transmission and Distribution Committee of the IEEE Power & Energy Society. IEEE recommended practice for monitoring electric power quality: IEEE Std. 1159—2009[S]. New York: The Institute of Electrical and Electronics Engineers, Inc, 2009.
 - [15] 王晓龙,唐贵基,周福成. 自适应可调品质因子小波变换在轴承早期故障诊断中的应用[J]. 航空动力学报,2017,32(10):2467-2475.
 - [16] 张涛,张明辉,李清伟,等. 基于粒子群-支持向量机的时间序列分类诊断模型[J]. 同济大学学报(自然科学版), 2016,44(9):1450-1457.
 - [17] 范小龙,谢维成,蒋文波,等. 一种平稳小波变换改进阈值函数的电能质量扰动信号去噪方法[J]. 电工技术学报, 2016,31(14):219-226.
 - [18] Martin V R, Rene J T, Roque A O, et al. Detection and classification of single and combined power quality disturbances using neural networks[J]. IEEE Transactions on Industrial Electronics, 2014, 61(5): 2473-2482.