



基于采样协方差矩阵的混合核 SVM 高效频谱感知

聂建园¹, 包建荣¹, 姜斌¹, 刘超¹, 朱芳¹, 何剑海²

(1. 杭州电子科技大学通信工程学院, 浙江 杭州 310018;

2. 宁波职业技术学院电子信息工程学院, 浙江 宁波 315800)

摘 要: 近年来随着盲检测算法的提出, 越来越多的基于采样协方差矩阵的盲检测算法应用于频谱感知。针对其检测门限是近似值, 检测性能会受到影响等问题, 提出了基于采样协方差矩阵的混合核函数的支持向量机 (support vector machine, SVM) 高效频谱感知, 通过感知信号采样协方差矩阵的最大最小特征值 (maximum minimum eigenvalue, MME) 和协方差绝对值 (covariance absolute value, CAV) 提取的统计量作为 SVM 的特征向量并训练其生成频谱感知的分类器, 无需计算检测门限并且特征提取减少了样本集的大小。利用遗传算法 (genetic algorithm, GA) 优化混合核函数的 SVM 的参数。实验结果表明, 该方法比 MME 算法和 CAV 算法的检测概率有所提高, 并且比 SVM 减少了感知时间, 具有良好的实用性。

关键词: 检测门限; 混合核函数; SVM; MME; GA

中图分类号: TN925

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2019210

An efficient spectrum sensing of mixed kernel SVM based on sampling covariance matrix

NIE Jianyuan¹, BAO Jianrong¹, JIANG Bin¹, LIU Chao¹, ZHU Fang¹, HE Jianhai²

1. School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

2. School of Electronic Information Engineering, Ningbo Polytechnic, Ningbo 315800, China

Abstract: In recent years, with the blind detection algorithms were proposed, more and more blind algorithms based on sampling covariance matrix were applied to spectrum sensing. The detection threshold was an approximation, and the detection performance would be affected for this algorithms. Thus, the mixed kernel function support vector machine (SVM) efficient spectrum sensing based on sampling covariance matrix was proposed. The statistics which were maximum minimum eigenvalue (MME) and covariance absolute value (CAV) of sensing signal sampling covariance matrices were used as the feature vectors of SVM and were trained to generate a spectrum sensing classifier.

收稿日期: 2019-03-15; 修回日期: 2019-08-19

通信作者: 刘超, liuchao@hdu.edu.cn

基金项目: 浙江省自然科学基金资助项目 (No.LY17F010019); 国家自然科学基金资助项目 (No.U1809201); 浙江省公益性技术应用研究计划基金资助项目 (No.LGG18F010011, No.LGG19F010004)

Foundation Items: Natural Science Foundation of Zhejiang Province (No.LY17F010019), The National Natural Science Foundation of China (No.U1809201), Public Welfare Technology Application Research Program of Zhejiang Province (No.LGG18F010011, No.LGG19F010004)



The advantage of this algorithm was that it needn't calculate the detection threshold and the extraction of features reduces size of the sample set. The genetic algorithm (GA) was used to optimize the parameters of mixed kernel function SVM algorithm. The experimental results show that the proposed method has higher detection probability than MME and CAV algorithms, and has less sensing time than SVM, which has good practicability.

Key words: detection threshold, mixed kernel function, SVM, MME, GA

1 引言

传统的能量检测 (energy detection, ED) 算法简单, 所需时间短, 但是会受到噪声峰值影响, 不适合低信噪比的环境^[1]。匹配滤波检测精度高, 所需时间短, 然而需要主用户 (primary user, PU) 的先验信息^[2]。循环平稳特征检测的检测精度高, 支持在低信噪比下检测, 但是算法复杂度高, 检测时间最长^[3]。实际频谱感知的情中各种先验信息都是未知的, 基于协方差矩阵的盲检测算法越来越成为研究的热点^[4-7]。基于协方差矩阵的盲检测算法包括: 协方差绝对值 (covariance absolute value, CAV) 检测^[8]、最大最小特征值法 (maximum minimum eigenvalue, MME) 检测^[9-10]。参考文献^[11]提出最大最小特征值之差的双特征值估计法。这些算法可以消除一定的噪声不确定的影响, 提高检测概率。但是其设置的门限都是渐进的, 门限的不精确设置影响了算法的检测性能。并且随着近年来频谱感知结合机器学习算法的研究^[12-13], 其中, 包括基于支持向量机 (support vector machine, SVM) 的频谱感知^[14]。SVM 频谱感知算法的分类性能好坏关键在于核函数的选取以及各个参数的选择^[15]; 其中, 参考文献^[16]中利用粒子群优化算法优化 SVM 的各参数。本文利用遗传算法 (genetic algorithm, GA) 优化混合核 SVM 算法各参数并将 MME 和 CAV 算法的统计量作为特征向量, SVM 训练其生成分类器。此算法绕开了 MME 和 CAV 检测的渐进门限的设置, 从而提高了检测性能并且相对直接的 SVM 算法减小了样本集的大小。此外, 混合核函数结合了多项式核函数和径向基核函数

(radial basis function, RBF) 的优点, 提高了分类的精确率。

2 频谱感知系统模型

在典型的认知无线网络 (cognitive radio network, CRN) 中, 由一组 PU 发射机 (PU-transmitter, PU-T)、接收机 (PU-receiver, PU-R) 和 M 个次用户 (secondary user, SU) 组成, 如图 1 所示。假设 PU 与 SU 是属于不同的通信用户终端, 之间没有直接的信息交互, SU 难以得到 PU 的信道状态。在已被划分的频段中, 认知基站 (cognitive base station, CBS) 首先通过检测信道中的 PU, 判断 PU 的工作状况与哪些频谱是空闲的。然后, 它发送 PU-R 的状态并确定空闲频谱。当 PU-R 处于检测区域时, 实时检测继续进行, 直到它离开检测区域并释放先前占用的频谱。SU 可以重新利用这段频谱。若 SU 正使用的频谱被 PU 访问, 则 SU 要退出该频谱转入缓存中, 认知设备同时检测其他空闲频谱。




图 1 认知无线网络 (CRN) 架构

频谱感知的主要目标是感知 PU-R 是否在使用频谱, 根据 CRN 模型, SU 感知到的信号可以表示为二进制假设检验问题:

$$\begin{cases} H_0: x(k) = n(k) \\ H_1: x(k) = h(k) * s(k) + n(k) \end{cases} \quad (1)$$

其中, H_0 和 H_1 分别表示 PU 存在与否的假设; $x(k)$ 和 $h(k)$ 分别是第 k 个 SU 接收的感知信号和信道增益; $s(k)$ 和 $n(k)$ 代表第 k 个接收的 PU 信号序列和噪声, 且 $n(k) \sim N(0, \sigma_n^2)$ 。

M 个 SU 收集信号, 感知信号矩阵表示如式(2):

$$\hat{\mathbf{X}} = \begin{bmatrix} x_1(1) & x_1(2) & \cdots & x_1(N) \\ x_2(1) & x_2(2) & \cdots & x_2(N) \\ \vdots & \vdots & \ddots & \vdots \\ x_M(1) & x_M(2) & \cdots & x_M(N) \end{bmatrix} \quad (2)$$

其中, N 表示在一个时隙中感知信号的样本数。

感知信号和主用户信号的统计协方差矩阵分别为:

$$\mathbf{R}_x = E(\hat{\mathbf{X}} \hat{\mathbf{X}}^T) \quad (3)$$

$$\mathbf{R}_s = E(\mathbf{S} \mathbf{S}^T) \quad (4)$$

其中, $\mathbf{S}$ 为主用户信号构成的矩阵。

根据参考文献[6], 可以证明:

$$\mathbf{R}_x = \mathbf{R}_s + \sigma^2 \mathbf{I}_M \quad (5)$$

限于采样的有限性, 感知信号的采样协方差矩阵表示为:

$$\mathbf{R} = (1/N) \hat{\mathbf{X}} \hat{\mathbf{X}}^T \quad (6)$$

3 基于 MME 和 CAV 算法的 SVM 频谱感知

3.1 MME 检测算法

MME 检测算法是以感知信号的采样协方差矩阵 $\mathbf{R}$ 的最大和最小特征值比率构造出的统计量, 其表达式为:

$$T_{\text{MME}} = \lambda_{\max} / \lambda_{\min} \quad (7)$$

其中, $\lambda_{\max}$ 和 $\lambda_{\min}$ 分别为矩阵 $\mathbf{R}$ 的最大和最小特征值。

在假设 $N \rightarrow +\infty$ 且 $\lim_{N, M \rightarrow +\infty} M/N = c$, 其中, c 为常数。根据参考文献[9]得到判决门限为:

$$\gamma_{\text{MME}} = \frac{(\sqrt{N} + \sqrt{M})^2}{(\sqrt{N} - \sqrt{M})^2} \left(1 + \frac{(\sqrt{N} + \sqrt{M})^{-\frac{2}{3}}}{(NM)^{\frac{1}{6}}} \right) F_1^{-1}(1 - P_f) \quad (8)$$

其中, F_1^{-1} 表示 Tracy-Widom 第一分布的累积分布函数。

3.2 CAV 检测算法

该检测算法利用两种假设, PU 信号的存在与否, 得到感知信号的采样协方差矩阵的不同进行检测频谱, 其统计量的构造如式(9):

$$T_{\text{CAV}} = T_1 / T_2 \quad (9)$$

其中, $T_1 = \sum_{1 \leq i, j \leq M} \frac{|r_{ij}|}{N}$, $T_2 = \sum_{1 \leq i \leq M} \frac{|r_{ii}|}{N}$, 且 r_{ij} 表示式(6)中 $\mathbf{R}$ 矩阵的第 i 行、第 j 列的元素。

在假设 $N \rightarrow +\infty$, 根据参考文献[8], 其检测门限为:

$$\gamma_{\text{CAV}} = \frac{1 + (M-1)\sqrt{2/N\pi}}{1 - Q^{-1}(P_f)\sqrt{2/N\pi}} \quad (10)$$

其中, $Q(x) = \frac{1}{\sqrt{2\pi}} \int_x^{+\infty} e^{-u^2/2} du$ 。

3.3 SVM 频谱感知算法

利用在频谱感知中以 PU 信号的状态为目标, PU 信号的存在与否是 1 与 -1 的离散关系, 该情形满足 SVM 离散分类性质。

结合前面第 2.1 节和第 2.2 节构造的统计量, 构造的特征向量 $\mathbf{x}$ 分别为: $\mathbf{x} = [T_{\text{MME}1}, T_{\text{MME}2}, \dots, T_{\text{MME}M}]$ 和 $\mathbf{x} = [T_{\text{CAV}1}, T_{\text{CAV}2}, \dots, T_{\text{CAV}M}]$, 并且其对应的标签为 f_i 。于是得到训练集为: $G = \{(\mathbf{x}_i, f_i)\}$, 并且标签 $f_i \in \{-1, 1\}$ 。

对于频谱感知属于非线性的分类问题, SVM 中需要增加一个松弛变量 ξ_i 来调整余量, 最优化的问题变为:

$$\min_{\mathbf{w}} \frac{1}{2} \|\mathbf{w}\|^2 + C \left(\sum_{i=1}^L \xi_i \right) \quad (11)$$

$$\text{s.t. } f_i [(\mathbf{w} \cdot \mathbf{x}_i) + b] \geq 1 - \xi_i, i = 1, 2, \dots, L \quad (12)$$

其中, C 为惩罚系数, $\mathbf{w}$ 为超平面的法向量, L 为



样本数量。

式 (11) 和式 (12) 通过拉个朗日乘子法及其对偶问题^[17], 得到优化问题式 (13) 和式 (14):

$$\max_{\alpha} \sum_{i=1}^L \alpha_i - \frac{1}{2} \sum_{i,j=1}^L \alpha_i \alpha_j f_i f_j \mathbf{x}_i^T \mathbf{x}_j \quad (13)$$

$$\text{s.t.} \sum_{i=1}^L f_i \alpha_i = 0, 0 \leq \alpha_i \leq C, i=1, 2, \dots, L \quad (14)$$

其中, α 为拉个朗日乘子。

最终的决策函数为:

$$y = \text{sign}(\sum_{i=1}^L \alpha_i f_i K(\mathbf{x}_i, \mathbf{x}_j) + b) \quad (15)$$

其中, y 代表 PU 的存在与否。若 $y=1$ 代表假设 H_1 , 即 PU 信号存在, 否则代表 PU 信号不存在。

线性、多项式和 RBF 核函数分别表示为式 (16)、式 (17) 和式 (18):

$$K_{\text{linear}} = \langle \mathbf{x}_i, \mathbf{x}_j \rangle \quad (16)$$

$$K_{\text{poly}} = [(\mathbf{x}_i \cdot \mathbf{x}_j) + 1]^q \quad (17)$$

$$K_{\text{RBF}} = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / \sigma^2) \quad (18)$$

构造混合核函数并且其满足 Mercer 条件:

$$K_{\text{mix}} = aK_{\text{poly}} + (1-a)K_{\text{RBF}} = a[(\mathbf{x}_i \cdot \mathbf{x}_j) + 1]^q + (1-a)\exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / \sigma^2) \quad (19)$$

其中, a 为混合核函数权重系数, $a \in (0, 1)$ 。

因为惩罚系数 C 决定了最小化拟合误差与最小化模型的复杂性之间的权衡; RBF 的核参数 σ 反映了训练数据的特征, 并且对 SVM 系统的泛化能力有很大的影响^[17]。所以参数的选择对 SVM 系统的分类模型的精确率有重大影响。考虑到遗传算法具有寻找最优参数的能力。故本文利用遗传算法对 SVM 的参数进行优化。其中包括权重系数 a 、多项式函数阶数 q 、RBF 核参数 σ 和惩罚因子 C 。算法的流程如图 2 所示。

步骤 1 初始化种群及种群规模和染色体。

步骤 2 将染色体解码为权重系数 a 、多项式阶数 q 、RBF 核参数 σ 和惩罚因子 C 。




图 2 遗传算法优化 SVM 参数的流程

步骤 3 以分类精确率作为适应度函数并计算其值; 核函数性能通过分类精确率来衡量, 定义为在测试时正确分类的样本和测试观察的总样本数之比。

步骤 4 判断是否达到最大迭代次数, 如果达到则退出循环并输出最优参数值, 否则转步骤 5。

步骤 5 将 SVM 模型参数编码为染色体。

步骤 6 对染色体执行选择、交叉、变异算子; 这样既保证了适应度函数值大的染色体保留下来, 又能保证下一代种群的变化。形成新一代染色体后继续执行步骤 2。

4 仿真结果

实验采用检测概率 P_d 和虚警概率 P_f 作为频谱感知的衡量指标。平均错误概率 $P_e = 0.5(P_m + P_f)$, 其中, P_m 为漏警概率。仿真参数设置如下: BPSK 信号作为 PU 信号; 载波的频率为 2 MHz; 噪声服从 $n(k) \sim N(0, 1)$ 。并通过控制信噪比的大小来改变 PU 的幅值。在信号维数 N 为 100 的情况下, 执行蒙特卡洛仿真 2 000 次。

本文首先根据经验初始化 SVM 算法的参数 $(C, q, \sigma, a) = (500, 2, 2, 0.5)$, 其次, 通过遗传算法对参数 (C, q, σ, a) 进行优选, 其中, a 、 C 和 σ 的取值范围分别为 $(0, 1)$ 、 $[1, 1000]$ 和 $(0, 10)$, q 的取值为 1 到 10 的整数。 a 、 C 、 σ 和 q 的步长分别为 $1/1024$ 、 $1000/1024$ 、 $10/1024$ 和 1。染色体对应的编码范围为: 0000000001~1111111111。

在参数的寻优过程中,一个染色体代表一个参数。种群由各个染色体组成并且适应度函数值为各染色体上对应的适应度函数值之和的平均。GA 算法中,染色体长度为 10,迭代次数为 100,交叉概率取 0.6,变异概率取 0.01。

图 3 为 GA 优化混合核 SVM 参数的适应度函数值随着迭代次数的变化而变化。经选择、交叉、变异等操作,每次迭代时与之前的最优函数值比较,如果适应度函数更大,则替换此次适应度函数值和对应的参数,这样迭代的染色体继承了上一代的优良特性,并逐步朝着最优解方向进化。在最优的适应度函数值达到 0.844 时对应的参数 (C, q, σ, a) 分别为 (658, 2, 2.469, 0.023)。




图3 GA算法中迭代次数和适应度函数值的关系

在训练和测试样本分别为 1 000, 认知用户数 $M=5$, 并且设置多项式核函数的阶数 $q=2$, RBF 的核参数 $\sigma=2.469$, 混合核函数中的参数设定为 $a=0.023$ 。仿真得到 4 种核函数测试分类精确率。

在不同的信噪比下 SVM 的 4 种核函数精确率的比较如图 4 所示, 其中, 线性核函数精确率最低, 且在 50% 左右; 多项式核函数和 RBF 的精确率接近且优于线性核函数。并且, 在信噪比为 -20 dB 时, 混合核函数的精确率比 RBF 和多项式核函数的精确率高约 20%。从理论方面分析如下。

(1) 对比线性核函数, RBF 更适合非线性可分情况下的样本数据, 可以把低维非线性空间映射到高维线性空间, 而且线性核函数本身也属于 RBF 核函数的一个特例。




图4 各核函数精确率比较

(2) 与多项式核函数相比, RBF 核值在归一化后, 具有避开无线环境中多重计算量大的障碍, 可以大大减小高维计算量, 而多项式的阶数变得较大时, 运算量会极大提高。

(3) 当维数不大、数据量也不大的情况下, 利用多项式核函数的性能效果也是与 RBF 逼近的, 因为适当提高阶数可以提高分类的准确率。RBF 是局部核函数, 多项式核函数是全局核函数。局部核函数学习能力强, 泛化性能弱; 全局核函数学习能力强, 泛化性能强。混合核函数可以综合这两类核函数的优点, 得到更高的分类精确率; 故本文选择混合核函数。

图 5 中 GA-SVM 代表遗传算法优化 SVM 参数算法; SVM 代表没有经过优化的参数算法。在信噪比为 -20 dB 时, GA 优化参数后的 SVM 算法在漏警概率 P_m 方面降低了 0.28, 在虚警概率 P_f 方面




图5 GA优化SVM参数前后的频谱感知性能



降低了 0.29; 即 GA 优化参数后的 SVM 的频谱具有更好的感知性能。故接下来仿真的 SVM 均是经 GA 优化参数后的算法。

图 6 中相同的信噪比下, 检测概率方面基于采样协方差矩阵的 SVM 频谱感知包括 MME/SVM 和 CAV/SVM 总是优于传统的最大最小特征值 MME 和协方差绝对值 CAV 检测算法。这是因为 MME 和 CAV 算法推导门限时, 使用了极限近似理论, 即在 $N \rightarrow +\infty$ 和 $\lim_{N, M \rightarrow +\infty} M/N = c$ 的假设条件下, MME 和 CAV 检测算法的判决门限式 (8) 和式 (10) 均为近似值。而 MME/SVM 和 CAV/SVM 算法通过 SVM 对 MME 和 CAV 的统计量训练, 生成频谱感知的分类器, 无需求得精确的门限值。并且在 -15 dB 时, 能量检测 ED、CAV、MME、MME/SVM 和 CAV/SVM 的检测概率分别为 25%、60%、63%、96%、89%。




图 6 在不同信噪比下, 各算法检测概率比较

图 7 中显示了在相同的信噪比下, 相对能量检测 (ED), 基于 MME 的 SVM 频谱感知 MME/SVM 和基于 CAV 的 SVM 频谱感知 CAV/SVM 具有更低的平均错误概率 P_e ; 这是因为在低信噪比下, PU 信号可能会被噪声完全覆盖, ED 算法的感知性能将会受到限制。但是 MME/SVM 和 CAV/SVM 算法中, 通过 SVM 算法, 绕开了 PU 与噪声混杂的情况, 将低维空间通过非线性变化得到高维空间, 随后超平面将 PU 和噪声分割开。因此, 其平均错误概率 P_e 低

于 ED 检测。相对于 SVM 算法, MME/SVM 和 CAV/SVM 检测的错误概率降低的速率更快, 并且随着 SU 数量 M 的增加, P_e 略微下降, 这也符合协作频谱感知的检测思想。




图 7 不同次用户数量下, 各算法平均错误概率

图 8 显示了在不同的信噪比 SNR 和相同虚警概率 P_f 时, 信噪比较大的检测概率更大, 即漏警概率 P_m 更小, 说明信噪比变大可以使信号能量随之变得更大, 也能更好地提高检测性能, 在相同的 SNR 下, 两种检测随着虚警概率 P_f 变得更大, 其检测概率也相应提升, 说明虚警概率的增大有助于算法检测的灵敏度提升, 当 P_f 达到 1 时, 不同信噪比下两种检测算法的检测概率也达到最大。在相同的信噪比和虚警概率下, MME/SVM 算法拥有更高的检测概率。在 -20 dB 时, MME/SVM 检测的性能要比 ED 在信噪比为 -10 dB 时的性能还要好。所以, MME/SVM 检测的性能要远优于能量检测的性能。




图 8 ED 和 MME/SVM 的 P_f - P_d 关系曲线

图9中归一化感知时间定义为 $\hat{t}: \hat{t}=(t-t_{\min})/(t_{\max}-t_{\min})$; 其中, $t_{\max}$ 和 $t_{\min}$ 分别代表最大和最小的感知时间。SVM算法和MME/SVM算法的感知时间包括: 测试数据的构造和测试过程。




图9 3种算法归一化感知时间比较

图9中ED和SVM算法的归一化感知时间随着信号的维数增大而增大,但是MME/SVM的归一化感知时间不会随着信号维数的变化而变化,并且在相同维数下,感知时间均低于ED和SVM。这是由于SVM算法的输入未处理的感知信号样本,样本维度较大,会增加系统的复杂性,导致感知时间长。假设 L_2 是测试过程样本数量;感知信号的测试集大小为: $L_2 \times M \times N$ 。通过MME构造的统计量,样本减少到: $L_2 \times M$,相对于直接的SVM频谱感知,极大地减少了样本数量,减少了感知时间,并且感知时间与信号维数 N 无关。

本文采用混合核的SVM感知算法,由于SVM是借助二次规划来求解支持向量,而求解二次规划将涉及 L_1 阶矩阵的计算(L_1 为训练样本数),当训练样本数较小时,SVM分类器没有得到充分的学习。当训练数目很大时,该矩阵的存储和计算将耗费大量的机器内存和训练时间。如何在保证检测性能的前提下减少训练时间,将是下一步研究的重点。

5 结束语

本文利用MME和CAV算法的统计量作为混

合核SVM算法的特征向量,训练其生成频谱感知分类器。并且利用遗传算法优化混合核SVM算法的参数。MME和CAV算法的检测门限都是在极限理论上推导得到的,故其检测门限均是渐进门限,检测门限设定不合适,频谱检测性能将会受到影响。本文算法不需要直接计算检测门限,而是利用统计量生成合适的频谱分类器,并且统计特征的提取使得输入SVM分类器的样本减小,从而减少感知时间。

参考文献:

- [1] LI B, SUN M, LI X, et al. Energy detection based spectrum sensing for cognitive radios over time-frequency doubly selective fading channels[J]. IEEE Transactions on Signal Processing, 2015, 63(2): 402-417.
- [2] ZHANG X, GAO F, CHAI R, et al. Matched filter based spectrum sensing when primary user has multiple power levels[J]. China Communications, 2015, 12(2): 21-31.
- [3] DU J, HUANG H, JING X J, et al. Cyclostationary feature based spectrum sensing via low-rank and sparse decomposition in cognitive radio networks[C]//2016 16th International Symposium on Communications and Information Technologies (ISCIT), September 26-28, 2016, Qingdao, China. Piscataway: IEEE Press, 2016: 615-619.
- [4] YANG X, LEI K J. Blind detection for primary user based on the sample covariance matrix letters in cognitive radio[J]. IEEE Communications Letters, 2013, 15(1): 40-42.
- [5] 刘顺兰, 王静, 包建荣. 高检测概率协方差矩阵机会协作频谱感知[J]. 电信科学, 2019, 35(1): 67-73.
LIU S L, WANG J, BAO J R. Covariance matrix opportunistic cooperative spectrum sensing of high detection probability[J]. Telecommunications Science, 2019, 35(1): 67-73.
- [6] LI Z, ZHOU F, SI J, et al. Feasibly efficient cooperative spectrum sensing scheme based on Cholesky decomposition of the correlation matrix[J]. IET Communications, 2016, 10(9): 1003-1011.
- [7] ZHOU F, BEAULIEU N C, LI Z, et al. Feasibility of maximum eigenvalue cooperative spectrum sensing based on Cholesky factorization[J]. IET Communications, 2016, 10(2): 199-206.
- [8] 李有均. 基于随机矩阵的协作频谱感知算法研究[D]. 重庆: 重庆大学, 2017.
LI Y J. Cooperative spectrum sensing algorithm based on random matrix[D]. Chongqing: Chongqing University, 2017.
- [9] PUTRI S M, SUGIHARTONO I. Energy efficiency in cogni-



- tive radio with cooperative MME (maximum to minimum eigenvalue) spectrum sensing method[C]//2015 International Seminar on Intelligent Technology and Its Applications (ISITIA), May 20-21, 2015, Surabaya, Indonesia. Piscataway: IEEE Press, 2015: 379-384.
- [10] WAEL C B A, ARMI N, ROHMAN B P A. Spectrum sensing for low SNR environment using maximum-minimum eigenvalue (MME) detection[C]//2016 International Seminar on Intelligent Technology and Its Applications (ISITIA'16), July 28-30, 2016, Lombok, Indonesia. Piscataway: IEEE Press, 2016: 435-438.
- [11] 赵知劲, 胡伟康, 王海泉. 基于双特征值极限分布的合作频谱感知算法[J]. 电信科学, 2014, 30(4): 82-87.
ZHAO Z J, HU W K, WANG H Q. Cooperative spectrum sensing algorithm based on double eigenvalue limiting distribution[J]. Telecommunications science, 2014, 30(4): 82-87.
- [12] WANG F, ZHEN Z, WANG B, et al. Comparative study on KNN and SVM based weather classification models for day ahead short term solar PV power forecasting[J]. Applied Sciences, 2018, 8(1): 3-5.
- [13] 赵知劲, 陈京来. 蜂群优化神经网络的频谱感知[J]. 信号处理, 2016, 32(1): 77-82.
ZHAO Z J, CHEN J L. A neural network spectrum sensing algorithm using bee colony optimization[J]. Signal Processing, 2016, 32(1): 77-82.
- [14] 聂勇, 叶翔, 翟旭平. 基于支持向量机和噪声估计的宽带频谱感知方法[J]. 电子测量技术, 2017, 40(12): 88-92.
NIE Y, YE X, ZHAI X P. Wideband spectrum sensing method based on SVM and EN[J]. Electronic Measurement Technology, 2017, 40(12): 88-92.
- [15] 翟旭平, 杨兵兵, 孟田. 基于PCA和混合核函数QPSO_SVM频谱感知算法[J]. 电子测量技术, 2016, 39(9): 87-90, 107.
ZHAI X P, YANG B B, MENG T. Spectrum sensing based on PCA and QPSO_SVM with mixed kernel[J]. Electronic Measurement Technology, 2016, 39(9): 87-90, 107.
- [16] 翟旭平, 孟田, 杨兵兵. 基于SOM-SVM频谱感知算法[J]. 电子测量技术, 2016, 39(10): 76-80.
ZHAI X P, MENG T, YANG B B. Spectrum sensing algorithm based on SOM-SVM[J]. Electronic Measurement Technology, 2016, 39(10): 76-80.
- [17] 加尔·肯别克, 袁杰. 变样本量学习最小二乘支持向量机

算法[J]. 计算机工程, 2019, 45(1): 192-198, 205.

JIAE K, YUAN J. Variable samples learning least square support vector machine algorithm[J]. Computer Engineering, 2019, 45(1): 192-198, 205.

[作者简介]



聂建园 (1994-), 女, 杭州电子科技大学硕士生, 主要研究方向为认知无线电频谱感知、压缩感知等。



包建荣 (1978-), 男, 博士后, 杭州电子科技大学教授、博士生导师, 主要研究方向为空间无线通信、通信信号处理与自主无线电等。



姜斌 (1980-), 男, 现就职于杭州电子科技大学, 主要研究方向为空间无线通信、无线传感器网络等。

刘超 (1977-), 男, 博士, 杭州电子科技大学副教授, 主要研究方向为无线通信、计算机通信网等。

朱芳 (1973-), 男, 博士, 杭州电子科技大学讲师, 主要研究方向为无线通信和信息安全等。

何剑海 (1979-), 男, 博士, 宁波职业技术学院副教授, 主要研究方向为认知无线电、协同通信等。