

基于特征值极限分布的双门限 DMM 频谱感知算法

高 鹏¹, 刘芸江¹, 高维廷¹, 李 曼²

(1. 空军工程大学 信息与导航学院, 西安 710077; 2. 西安航空学院, 西安 710077)

摘 要: 采用随机矩阵特征结构理论, 分析并研究多认知用户采样协方差矩阵的特征极限值分布, 提出一种基于最大最小特征值之差(DMM)的双门限频谱感知算法。根据最大与最小特征极限值分布推导检测双门限, 对双门限内外部分分别采用软判决与硬判决综合得到最终判决结果。利用特征值噪声估计实现检测门限的自适应, 克服噪声不确定性对频谱感知的影响。仿真结果表明, 在低信噪比、虚警率和采样频率的情况下, 该算法检测性能优于 DMM 算法与能量检测算法, 且稳定性好、鲁棒性强。

关键词: 认知无线电; 频谱感知; 随机矩阵理论; 特征值极限分布; 最大最小特征值之差

中文引用格式: 高 鹏, 刘芸江, 高维廷, 等. 基于特征值极限分布的双门限 DMM 频谱感知算法[J]. 计算机工程, 2017, 43(9): 68-74.

英文引用格式: GAO Peng, LIU Yunjiang, GAO Weiting, et al. Double Threshold DMM Spectrum Sensing Algorithm Based on Limiting Eigenvalue Distribution[J]. Computer Engineering, 2017, 43(9): 68-74.

Double Threshold DMM Spectrum Sensing Algorithm Based on Limiting Eigenvalue Distribution

GAO Peng¹, LIU Yunjiang¹, GAO Weiting¹, LI Man²

(1. College of Information and Navigation, Air Force Engineering University, Xi'an 710077, China;

2. Xi'an Aeronautical University, Xi'an 710077, China)

[Abstract] This paper uses the Random Matrix Theory(RMT) of eigen structure, analyzes and researches the limiting eigenvalue distribution of sampling covariance matrix for multiple cognitive users, and proposes a double threshold spectrum sensing algorithm based on Difference Between the Maximum Eigenvalue and the Minimum Eigenvalue (DMM). The double thresholds are obtained by using the limiting eigenvalue distribution of both maximum and minimum eigenvalues. The soft decision and hard decision are adopted in both internal and external parts of the double threshold to achieve the final decision result. The self-adaptability of detected thresholds is realized by using eigenvalue noise estimation, which overcomes the impact of noise uncertainty on spectrum sensing. The simulation result shows that the algorithm has better detection performance than the DMM algorithm and Energy Detection(ED) algorithm under the situation of low signal noise ratio, low false alarm probability and relatively small number of sampling points, and it has good stability and strong robustness.

[Key words] Cognitive Radio(CR); spectrum sensing; Random Matrix Theory(RMT); limiting eigenvalue distribution; Difference Between the Maximum Eigenvalue and the Minimum Eigenvalue(DMM)

DOI: 10.3969/j.issn.1000-3428.2017.09.013

0 概述

认知无线电(Cognitive Radio, CR)是实现频谱资源共享, 解决目前频谱资源紧张的重要技术^[1]。频谱感知作为认知无线电的前提基础和重要环节, 通过实时检测频谱空洞, 能准确判断主用户(Primary

User, PU)是否存在空闲频率资源, 以供认知用户(Secondary User, SU)接入使用。

现有的频谱感知算法主要有匹配滤波检测^[2]、循环平稳特征检测^[3]、能量检测^[4]、多用户协作检测^[5]等。匹配滤波要求主用户信号先验, 以此设计滤波器结构, 不符合实际应用; 循环平稳特征检测性

基金项目: 国家自然科学基金(61571364); 中国博士后科学基金(2016M603044)。

作者简介: 高 鹏(1992—), 男, 硕士研究生, 主研方向为认知无线电频谱感知; 刘芸江, 副教授、博士; 高维廷, 讲师、博士; 李 曼, 副教授、博士。

收稿日期: 2017-01-17 **修回日期:** 2017-02-24 **E-mail:** meickey123@163.com

能较好,但计算复杂度高、实时性差;能量检测简单易实现,对主用户信号非先验,但其性能受噪声不确定度影响大,存在信噪比(Signal Noise Ratio, SNR)门限要求;利用多输入多输出(Multiple Input Multiple Output, MIMO)^[6]、数据融合、双门限判决^[7]等技术的多用户协作检测近年来得到了一定的发展,但基于能量检测的本质仍无法克服噪声不确定性带来的影响。

将随机矩阵理论(Random Matrix Theory, RMT)^[8]的研究成果引入频谱感知领域,利用随机矩阵的特征结构在无限维度呈现的特殊收敛性质,避免了噪声不确定性的影响,为频谱感知开辟了新思路。文献[9]以最大最小特征值之比构造统计量提出 MME 算法,利用 Wishart 矩阵最小特征值的极限值和最大特征值的 Tracy-Widom 分布克服了噪声不确定性的影响,在低信噪比下取得了较好的检测性能,但恒定的阈值不符合实际应用场景。文献[10]以最大最小特征值之差(Difference Between the Maximum Eigenvalue and the Minimum Eigenvalue, DMM)构造统计量提出 DMM 算法,具有动态可变的阈值,进一步拓深了该领域的发展。文献[11]参考能量检测中双门限的方法将双门限(Double Eigenvalue, DT)检测引入随机矩阵理论频谱感知中。文献[12]吸纳了双门限判决的精确度好、鲁棒性强的优势,结合双门限与 MME 算法提出了新的判决规则。本文参考文献[12]的设计思路,结合 DMM 算法与双门限判决方法,分析 2 种特征值极限分布,提出一种基于 DMM 的双门限频谱感知算法。

1 检测模型与 DMM 算法

1.1 实际频谱感知场景

如图 1 所示,在认知无线网络中^[11],主用户(PU₁, PU₂, PU₃)通过主基站(Primary Base Station, PBS)进行通信。认知用户(SU₁, SU₂, SU₃)协同对 PU 信号进行检测,并将检测数据送至次级基站(Second Base Station, SBS)进行数据处理,判断 PU 使用的频段是否存在频率空洞,可供 SU 使用。

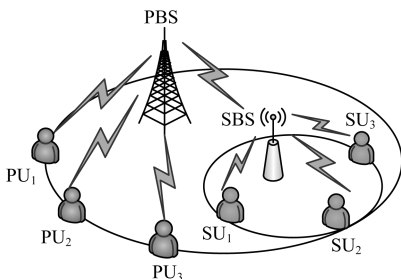


图 1 实际频谱感知场景

1.2 频谱感知模型

本文采用认知无线电中经典的二元假设数学模型^[1],假设在窄带的认知无线网络中,只存在一个主用户,认知用户对其信号进行检测判决,描述如下:

$$x_i(n) = \begin{cases} \omega_i(n), H_0 \\ h_i(n)s_i(n) + \omega_i(n), H_1 \end{cases}$$

其中, H_0 与 H_1 分别代表主用户信号存在与不存在的情况; $x_i(n)$ 为第 i 个认知用户接收到的采样信号; $s_i(n)$ 与 $\omega_i(n)$ 分别为待测主用户信号和干扰噪声; $h_i(n)$ 为信道衰落因子。

不失一般性,假设如下:1) 干扰噪声为高斯白噪声,并且服从 $\omega_i(N) \sim N(0, \sigma^2)$; 2) 主用户信号 $s_i(n)$ 幅值服从均值为 μ 、方差为 σ^2 的高斯分布,且与噪声相互独立; 3) M 个认知用户检测一个主用户的同一频段; 4) 在检测期间,信道特性稳定, $h_i(n)$ 保持不变。

对于 M 个认知用户采样 N 次,多用户协作频谱感知模型可以概括为:

$$X = Hs + n$$

其中, X 为 $M \times N$ 的矩阵,每个元素 $x_i(n)$ ($i = 1, 2, \dots, M; k = 1, 2, \dots, N$) 表示的是第 i 个认知用户在时刻 n 的采样值。采样信号协方差在 N 较大时,近似表示为:

$$R_x(N) = \frac{1}{N} \sum_{n=0}^{N-1} x(n)x(n)^T = \frac{1}{N} XX^T$$

当 H_0 成立时,只存在高斯白噪声, $R_x(N) = \sigma^2 I_M$,最大特征值 λ_{\max} 与最小特征值 λ_{\min} 均为 σ^2 。

当 H_1 成立时,因为 $s(n)$ 自身不同采样时刻具有相关性,所以使得最大最小特征值不相等, $\lambda_{\max} = \rho_{\max} + \sigma^2$, $\lambda_{\min} = \rho_{\min} + \sigma^2$, ρ_{\max} 与 ρ_{\min} 分别为 $R_{Hs}(N)$ 的最大与最小特征值。接收信号的最大最小特征值在主用户存在时的差异性为检测提供了思路。

1.3 DMM 算法

DMM 算法的核心思想在于用特征值极值之差衡量 H_0 与 H_1 下的差异性大小^[10]。在理想状况下, $\lambda_{\max} - \lambda_{\min}$ 的值在无主用户信号时为 0,因此,构造的检测统计量表示如下:

$$T_{\text{DMM}} = \lambda_{\max} - \lambda_{\min} \begin{matrix} H_1 \\ > \\ H_0 \end{matrix} \gamma_{\text{DMM}}$$

其中, γ_{DMM} 为判决门限, γ_{DMM} 的取值影响着检测性能, γ_{DMM} 的推导是通过 Wishart 随机矩阵的最大特征值极限分布,利用 λ_{\min} 的极限近似值确定。

定理 1 当信号为实信号时,满足^[13]:

$$A(N) = \frac{N}{\sigma^2} R_{\omega}(N)$$

当其中参数满足 $\mu = (\sqrt{N-1} + \sqrt{M})^2$ 和 $v = (\sqrt{N-1} + \sqrt{M})(1/\sqrt{N-1} + 1/\sqrt{M})^{1/3}$ 时,在 $\lim_{N \rightarrow \infty} \frac{M}{N} = c (0 < c < 1)$ 时, $\frac{\lambda_{\max}(A(N)) - \mu}{v}$ 服从一阶

Tracy-Widom 分布 $F_1(t)$, $\lambda_{\max}(A(N))$ 为随机矩阵 $A(N)$ 的最大特征值。

定理 2 当满足 $\lim_{N \rightarrow \infty} \frac{M}{N} = c (0 < c < 1)$ 时, Wishart 随机矩阵特征值极限表达式为^[14]:

$$\lim_{N \rightarrow \infty} \lambda_{\min} = \frac{\sigma^2}{N} a = \frac{\sigma^2}{N} (\sqrt{N} - \sqrt{M})^2$$

$$\lim_{N \rightarrow \infty} \lambda_{\max} = \frac{\sigma^2}{N} b = \frac{\sigma^2}{N} (\sqrt{N} + \sqrt{M})^2$$

其中, a, b 分别为 $M-P$ 定律中最小最大特征值的收敛值, 且 $a = \sigma^2 (1 - \sqrt{c})^2$, $b = \sigma^2 (1 + \sqrt{c})^2$ 。

DMM 算法虚警概率表示为:

$$P_{fa} = P(\lambda_{\max} - \lambda_{\min} > \gamma_{DMM} | H_0)$$

DMM 算法判决门限为:

$$\gamma_{DMM} = \frac{\sigma^2}{N} (v F_1^{-1}(1 - P_{fa}) + \mu - a)$$

采用文献[10]中特征值噪声估计法得到噪声方差 σ^2 :

$$\sigma^2 \approx (\sum_{i=1}^N \lambda_i - \lambda_{\max}) / (N - 1)$$

门限值与噪声能量有关, 在求特征值的过程中对噪声估计实时更新, 从而减小噪声能量对算法的影响。

$F_1^{-1}(t)$ 为 1 阶 Tracy-Widom 累计分布函数的反函数。采用文献[15]数值计算方法得到 $F_1(t)$ 与 $F_1^{-1}(t)$ 离散图像如图 2 所示, 常用数据如表 1 所示。

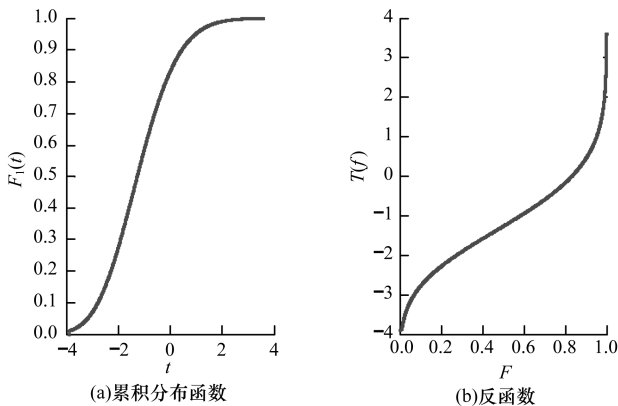


图 2 一阶 Tracy-Widom 累计分布函数与反函数

表 1 一阶 Tracy-Widom 累计分布函数部分数据

$F_1(t)$	t
0.01	-3.90
0.05	-3.18
0.10	-2.78
0.30	-1.91
0.50	-1.27
0.70	-0.59
0.90	0.45
0.95	0.98
0.99	2.02

由于 DMM 算法在计算判决门限时, 采用 λ_{\min} 的

近似值, 近似的条件是采样值 N 趋于无穷大, 而实际无法实现, 因此得到的判决门限不够准确, 继而影响了检测性能。

2 双门限 DMM 频谱感知算法

2.1 判决双门限的确定

随着随机矩阵理论研究的深入, Wishart 矩阵的最小特征值也服从 Tracy-Widom 分布^[16], 为新的判决门限推导提供了理论依据。

定理 3 当信号为实信号时, 满足^[16]:

$$A(N) = \frac{N}{\sigma^2} R_w(N)$$

当其中参数满足 $u = (\sqrt{N-1} - \sqrt{M})^2$ 和 $v = (\sqrt{N-1} - \sqrt{M}) (1/\sqrt{N-1} - 1/\sqrt{M})^{1/3}$ 时, 在

$\lim_{N \rightarrow \infty} \frac{M}{N} = c (0 < c < 1)$ 时, $\frac{\lambda_{\min}(A(N)) - u}{v}$ 服从一阶 Tracy-Widom 分布 $F_1(t)$, $\lambda_{\min}(A(N))$ 为随机矩阵 $A(N)$ 的最小特征值。

利用 Wishart 随机矩阵的最大特征值极限值, 通过最小特征值的 Tracy-Widom 分布确定判决门限为 γ_2 , 令之前 DMM 算法的门限为 $\gamma_1 = \gamma_{DMM}$ 。同样, 通过给定虚警概率 P_{fa} 的方式一一对应 γ_2 , 计算方式如下:

$$\begin{aligned} P_{fa} &= P(\lambda_{\max} - \lambda_{\min} > \gamma_2 | H_0) \\ &= P(\lambda_{\max} - \frac{\sigma^2}{N} \lambda_{\min}(A(N)) > \gamma_2) \\ &= P(\lambda_{\min}(A(N)) < \frac{N}{\sigma^2} (\lambda_{\max} - \gamma_2)) \\ &\approx P(\frac{\lambda_{\min}(A(N)) - u}{v} < \frac{(\sqrt{N} + \sqrt{M})^2 - N\gamma_2/\sigma^2 - u}{v}) \\ &= F_1(\frac{(\sqrt{N} + \sqrt{M})^2 - N\gamma_2/\sigma^2 - u}{v}) \end{aligned}$$

进一步整理得到:

$$\gamma_1 = \frac{\sigma^2}{N} (v F_1^{-1}(1 - P_{fa}) + \mu - a)$$

$$\gamma_2 = \frac{\sigma^2}{N} (b - u - v F_1^{-1}(P_{fa}))$$

当存在同一 P_{fa} 时, 判决门限值较低者, 检测概率高, 检测性能好。定性分析比较 γ_1 与 γ_2 , $F_1^{-1}(t)$ 为单调增函数, γ_1 随 P_{fa} 单调递减, γ_2 随 P_{fa} 单调递增, 大小关系无法判定。

采样点数 N 、认知用户数 M 、虚警概率 P_{fa} 共同决定了 γ_1 与 γ_2 的大小关系。令两门限差 $\Delta\gamma = \gamma_2 - \gamma_1$, 在 $M=5$ 时, 得到 $\Delta\gamma$ 与 N 和 P_{fa} 关系的三维曲线图, 如图 3、图 4 所示。由此可知, 切面为 $\Delta\gamma = 0$; 随着 N 与 P_{fa} 的变化, 曲线穿过截面意味着 γ_1 与 γ_2

的大小并不恒定;2 种角度下的三维曲线表明, M 与 P_{fa} 单方面都对 γ_1 与 γ_2 的大小关系有不同程度的影响;在不同情形下,对应的较低门限不同,进一步证明了设置双检测门限的合理性。

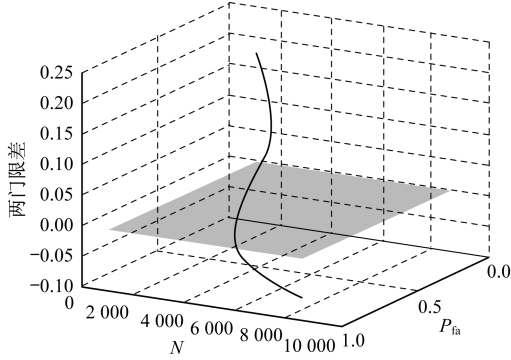


图 3 两门限差与采样点数和虚警概率的关系曲线 1

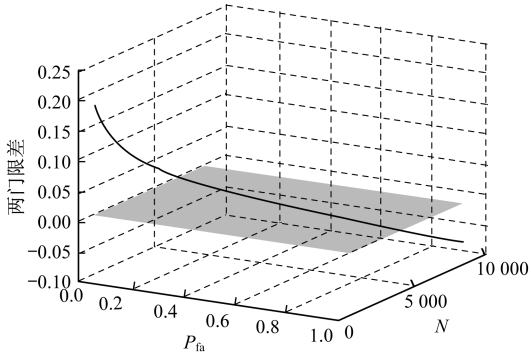


图 4 两门限差与采样点数和虚警概率的关系曲线 2

双门限的选取能够在不同情形下对应不同的门限值,理论上将提升检测性能。同时, γ_1 与 γ_2 所对应的检测统计量一致,将继承 DMM 算法抵抗噪声不确定性的能力。

2.2 算法原理

DMM 算法的判决门限 γ_1 与 γ_2 的推导都是利用最大或最小特征值其中之一特征极限分布,而对另者进行近似等效,等效的条件是采样点数趋于无穷大。对于有限维的接收信号协方差矩阵 $\mathbf{R}_x(N)$,用无限维的特征值的极限代替真实的特征值,会导致 λ_{\max} 较真实值偏大,而 λ_{\min} 偏小,因此无论 γ_1 与 γ_2 相较于理论上的门限都是偏大的,但不同情况程度不同。

利用双门限的方式,将 γ_1 与 γ_2 同时应用在不同的情形下,如图 5 所示,提出的新判决规则如下:

1) 当 $\lambda_{\max} - \lambda_{\min} < \min(\gamma_1, \gamma_2)$ 时,表示为未检测到主用户信号,硬判为 H_0 。

2) 当 $\lambda_{\max} - \lambda_{\min} > \max(\gamma_1, \gamma_2)$ 时,表示检测到主用户信号的存在,硬判为 H_1 。

3) 当 $\min(\gamma_1, \gamma_2) \leq \lambda_{\max} - \lambda_{\min} \leq \max(\gamma_1, \gamma_2)$ 时,累计次数做进一步判决,以 P_0 的概率判为 H_0 ,以 P_1 的概率判为 H_1 。

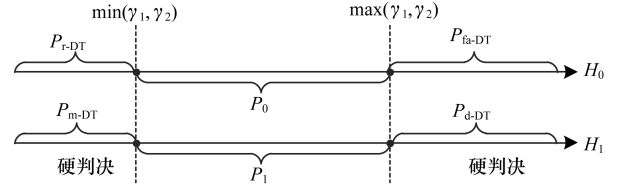


图 5 双门限判决示意图

双门限机制的核心思想在于利用 P_0 与 P_1 增加了软判决。对于采样信号的“特征明显”部分 $\lambda_{\max} - \lambda_{\min} < \min(\gamma_1, \gamma_2)$, $\lambda_{\max} - \lambda_{\min} > \max(\gamma_1, \gamma_2)$, 以硬判决的方式可以保证判决的准确性;对于两门限中间“特征模糊”部分,以软判决的方式予以划分,而划分的依据 P_0 与 P_1 的计算是通过在无限维度下的极限值与极限分布求得,中间“特征模糊”的部分相当于以理论界限予以划分。相较于传统的单门限硬判决,理论上性能的提升在于将“特征模糊”部分判决地更为准确。

P_0 表示在 H_0 的条件下,满足规则 3) 的概率, P_1 表示在 H_1 的条件下,满足规则 3) 的概率;采用最大值特征值的极限分布求虚警概率 P_{fa-DT} 与空洞概率 P_{r-DT} 。

$$P_0 = P(\min(\gamma_1, \gamma_2) \leq \lambda_{\max} - \lambda_{\min} \leq \max(\gamma_1, \gamma_2) | H_0) \\ = 1 - P_{fa-DT} - P_{r-DT}$$

P_{fa-DT} 计算方式如下:

$$P_{fa-DT} = P(\lambda_{\max} - \lambda_{\min} > \max(\gamma_1, \gamma_2) | H_0) \\ = P\left(\frac{\sigma^2}{N} \lambda_{\max}(\mathbf{A}(N)) > \max(\gamma_1, \gamma_2) + \lambda_{\min}\right) \\ \approx P(\lambda_{\max}(\mathbf{A}(N)) > \frac{N}{\sigma^2} \max(\gamma_1, \gamma_2) + a) \\ = P\left(\frac{\lambda_{\max}(\mathbf{A}(N)) - \mu}{v} > \frac{N \max(\gamma_1, \gamma_2) / \sigma^2 + a - \mu}{v}\right) \\ = 1 - F_1\left(\frac{N \max(\gamma_1, \gamma_2) / \sigma^2 + a - \mu}{v}\right)$$

P_{r-DT} 的计算方式如下:

$$P_{r-DT} = P(\lambda_{\max} - \lambda_{\min} < \min(\gamma_1, \gamma_2) | H_0) \\ = P\left(\frac{\sigma^2}{N} \lambda_{\max}(\mathbf{A}(N)) < \min(\gamma_1, \gamma_2) + \lambda_{\min}\right) \\ \approx P(\lambda_{\max}(\mathbf{A}(N)) < \frac{N}{\sigma^2} \min(\gamma_1, \gamma_2) + a) \\ = P\left(\frac{\lambda_{\max}(\mathbf{A}(N)) - \mu}{v} < \frac{N \min(\gamma_1, \gamma_2) / \sigma^2 + a - \mu}{v}\right) \\ = F_1\left(\frac{N \min(\gamma_1, \gamma_2) / \sigma^2 + a - \mu}{v}\right)$$

得到:

$$P_0 = 1 - P_{fa-DT} - P_{r-DT}$$

$$\approx F_1\left(\frac{N\max(\gamma_1, \gamma_2)/\sigma^2 + a - \mu}{v}\right) - F_1\left(\frac{N\min(\gamma_1, \gamma_2)/\sigma^2 + a - \mu}{v}\right)$$

算法检测概率为:

$$P_{d-DT} = P(\lambda_{\max} - \lambda_{\min} > \max(\gamma_1, \gamma_2) | H_1)$$

算法漏检概率为:

$$P_{e-DT} = P(\lambda_{\max} - \lambda_{\min} < \min(\gamma_1, \gamma_2) | H_1)$$

得到:

$$P_1 = P(\min(\gamma_1, \gamma_2) \leq \lambda_{\max} - \lambda_{\min} \leq \max(\gamma_1, \gamma_2) | H_1)$$

$$= 1 - P_{d-DT} - P_{e-DT}$$

基于 RMT 的算法复杂度主要来源于协方差矩阵的计算以及分解协方差矩阵求取特征值, 设置双门限后增加的软判决部分不涉及矩阵的运算。因此, 相较于 DMM 算法, 几乎不会带来算法复杂度的上升及影响检测的实时性。

2.3 算法步骤

DT-DMM 算法步骤具体如下:

1) 对检测信号采样, 计算获得待检信号的协方差矩阵 $\mathbf{R}_x(N)$ 。

2) 求取 $\mathbf{R}_x(N)$ 的所有特征值, 并构造检测量 $\lambda_{\max} - \lambda_{\min}$ 。

3) 根据 $\sigma^2 \approx (\sum \lambda_i - \lambda_{\max}) / (N - 1)$, 利用特征值对噪声进行估计, 并根据估计噪声计算特定虚警概率 P_{fa} 下的双门限 γ_1 与 γ_2 , 以及 P_0 与 P_1 。

4) 按上文叙述的判决方式, 对 $\lambda_{\max} - \lambda_{\min} < \min(\gamma_1, \gamma_2)$ 与 $\lambda_{\max} - \lambda_{\min} > \max(\gamma_1, \gamma_2)$ 的采样点, 分别硬判决为 H_0 与 H_1 。

5) 对 $\min(\gamma_1, \gamma_2) \leq \lambda_{\max} - \lambda_{\min} \leq \max(\gamma_1, \gamma_2)$ 的采样点, 分别以 P_0 与 P_1 的概率软判决为 H_0 与 H_1 。

6) 综合步骤 4) 与步骤 5) 软判决与硬判决的结果, 得到最终的判决结果。

3 仿真结果与性能分析

下面验证双门限 DMM 算法的检测有效性、检测性能以及抗噪声不确定性的能力。

3.1 H_0 下检测门限仿真分析

假设不存在主用户信号, 只输入高斯白噪声模拟 H_0 的检测场景。在认知用户数 $M = 5$ 、虚警概率 $P_{fa} = 0.1$ 时, 在不同的采样点数 N 下, 得到检测统计量 $\lambda_{\max} - \lambda_{\min}$ 与 DMM 算法、双门限 DMM 算法的检测门限的关系, 如图 6、图 7 所示。

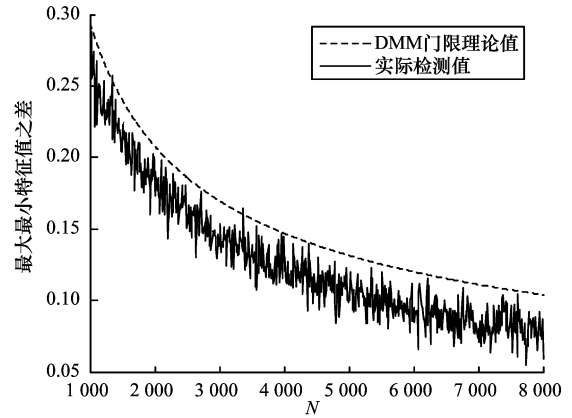


图 6 DMM 算法判决门限有效性检测结果

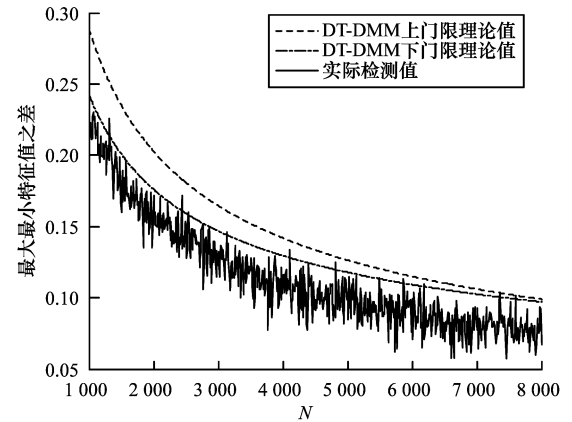


图 7 DT-DMM 算法判决门限有效性检测结果

从图 6 与图 7 的对比中可以得到, 在只有噪声的环境下, DT-DMM 算法的判决门限为下门限 $\min(\gamma_1, \gamma_2)$, 小于 DMM 算法的检测门限 γ_1 ; DT-DMM 实际检测量值绝大部分低于下门限理论值, 证明了门限选取的有效性, 少数超出理论值的点为设定虚警概率的结果。

相比 DMM 算法, DT-DMM 算法超出理论值的点数量略多, 因为在同样噪声功率输入下, 门限越低则越过门限的概率必然越大, 但对于 DMM 算法来说, 越过门限就意味着判为虚警点, 而对于 DT-DMM 算法来说因为有上门限的存在, 越过上门限才会被判为虚警点。该机制降低了虚警的概率, DT-DMM 检测量中超过上门限值的虚警点较 DMM 算法大大减少。在认知无线电实际应用中, 虚警意味着本为频谱空洞的情况下却检测到了主用户信号, 对于认知用户来说意味着错过了接入可用频谱的机会。对于 DT-DMM 算法来说, 虽然高于下门限的点数量多于 DMM 算法, 但下门限为硬判决门限, 采用软判决的方式再对两门限中间部分的点进行处理能够对 H_0 的判决带来一定的补偿。

单独分析图 7 得到,DT-DMM 算法的两门限值均随着采样点数的增加而下降,且差距越来越小、逐渐逼近。原因在于 γ_1 与 γ_2 均是通过半渐进的方式推导得出,以有限采样点替代无穷大,在采样点数不大的情况下,存在着数值的差异。当采样点逐渐增加时,差异性减小,直至在理想的无穷大处稳定。

3.2 H_1 下检测性能仿真分析

假设主用户信号为 QPSK 信号,经过 5 000 次 Monte-Carlo 仿真实验,在设定的虚警概率 P_{fa} 下,以获得的统计检测概率 P_d 为指标,与经典的 ED 算法、DMM 算法进行比较。

图 8 为在虚警概率为 0.05、认知用户数为 5、采样点为 5 000 时,检测概率与信噪比的关系,其中采用文献[10]对噪声不确定度的定义,以 ED- x 表示噪声不确定度为 x 的 ED 算法。在噪声不确定度为 0 时,ED 算法检测性能最优,在低信噪比 -20 dB 时,检测率可以达到 91%。但在实际应用中,噪声不确定度不容忽视,在噪声不确定度为 0.5 dB 与 1 dB 时,检测性能剧烈恶化,在低信噪比 -20 dB 下检测率分别为 20% 与 18%;而 DMM 算法与 DT-DMM 算法不受噪声不确定度的影响,一方面因为检测噪声通过特征值估计得到,另一方面最大最小特征值相减的检测统计量抵消了不确定性的影响。

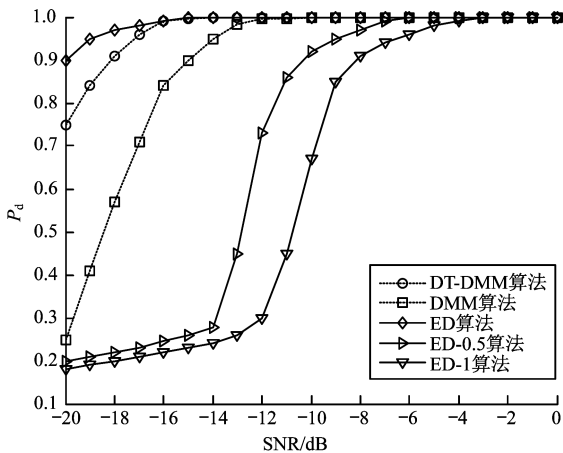


图 8 检测概率随信噪比的变化结果

在较低信噪比下,DT-DMM 算法相较 DMM 算法具有更好性能。在 -17 dB 时,DT-DMM 的检测概率已达到 95%,随着信噪比增加,两者检测性能均提升且逼近。同时,存在着一段信噪比增加的区域,ED 算法检测性能摆脱噪声不确定的影响快

速上升,而 DT-DMM 算法与 DMM 算法不存在“信噪比墙”的现象,具有更好的稳定性,且 DT-DMM 算法针对信噪比的变化鲁棒性更强,体现了双门限的优势。

图 9 为在虚警概率为 0.05、认知用户数为 5、信噪比为 -20 dB 时,检测概率与采样点的关系。旨在验证图 8 低信噪比的基础上,增加采样点数对检测性能的影响。以采样点 5 000 为起点,与图 8 比较得到,噪声不确定度为 0 的 ED 算法检测性能会随采样点增加而缓慢上升,但被噪声不确定度影响的 ED-0.5 与 ED-1 算法会在低检测率上仅有微小的增幅,几乎不存在显著变化,表明了无法通过增加采样点数来抵消 ED 算法噪声不确定度的影响。

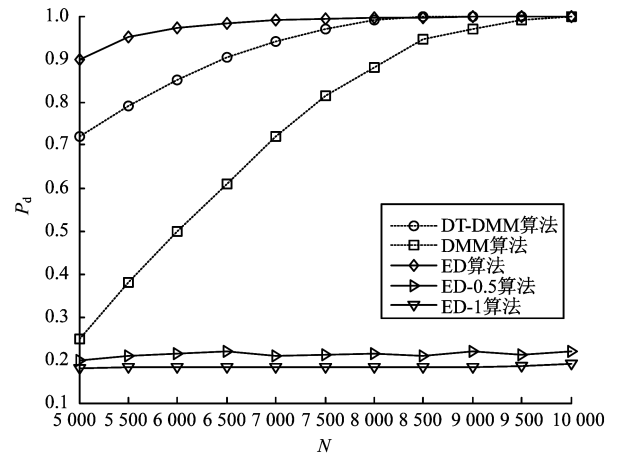


图 9 检测概率随采样点数的变化结果

随着采样点数的增加,DMM 算法与 DT-DMM 算法的检测性能均提升,但差距越来越小,DT-DMM 算法的优势会随着采样点数的增加而缩小,在样本数量不大的情况下,DT-DMM 算法会更具优势。原因在于 DT-DMM 算法衍生于 DMM 算法,其具有优势的原因在于双门限软判决的存在使得 H_0 与 H_1 的划分更为精确,当采样点数增加,特征值的近似值会越来越逼近极限值,从而减少 DT-DMM 在软判决部分的影响。在实际应用中,出于复杂度与实时性的考量,样本通常较小,也说明了 DT-DMM 算法更符合实际应用的需要。

图 10 为认知用户数为 5、信噪比为 -20 dB、采样点数为 5 000 时,在不同虚警概率下的 ROC (Receiver Operating Characteristics) 曲线图。随着虚警概率 P_{fa} 的增长,没有噪声不确定度的 ED 算法检测概率增长最快,其次为 DT-DMM 算法,但存在噪

声不确定度时 ED 算法检测概率增长最为缓慢,在较高的虚警概率(30%)下才勉强达到 0.69 与 0.78,进一步证明了 DT-DMM 算法在噪声不确定下的良好检测性能。

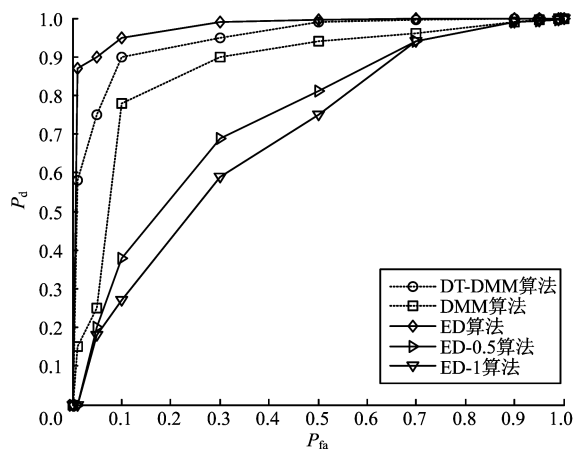


图 10 频谱感知算法 ROC 曲线

仿真结果表明,在不同信噪比、采样点数和虚警概率下,DT-DMM 算法的检测概率均优于 DMM 算法,更接近无噪声不确定度下能量检测算法的检测概率。

4 结束语

本文基于随机矩阵特征结构理论,利用最大与最小特征值的极限分布,在 DMM 频谱感知算法的基础上结合双门限检测原理,提出一种基于特征值极限分布的双门限 DMM 频谱感知算法。理论分析与仿真结果表明,该算法除继承 DMM 算法非先验、不受噪声不确定度的影响外,兼具双门限检测的稳定性好、鲁棒性强的优势,同时检测性能优于 DMM 算法与 ED 算法,更适用于低信噪比环境、有限采样下的认知无线电通信网络。下一步将对采样信号的门限中间值特征模糊部分做相应处理,以达到更好的检测性能。

参考文献

- [1] ROBERT C Q, ZHEN Hu, HUSHENG L, et al. 认知无线电通信组网:原理与组网[M]. 郎为民,译. 北京:机械工业出版社,2013.
- [2] SHOBANA S, SARAVANAN R, MUTHAIAH R. Matched Filter Based Spectrum Sensing on Cognitive Radio for OFDM WLANs[J]. International Journal of Engineering & Technology, 2013, 5(1): 141-146.
- [3] THAMIZHARASAN S, SARASWADY D, SAMINADAN V. Periodicity Based Cyclostationary Spectrum Sensing in Cognitive Radio Networks[J]. International Journal of Computer Applications, 2013, 68(6): 6-9.
- [4] SAIN T, SHARMA K. Optimization of Cooperative Spectrum Sensing with Energy Detection in Cognitive Radio Networks Using Voting Rule[J]. IEEE Transaction on Wireless Communication, 2015, 8(12): 5761-5766.
- [5] ALTHUNIBAT S, RENZO M D, GRANELLI F. Cooperative Spectrum Sensing for Cognitive Radio Networks Under Limited Time Constraints[J]. Computer Communications, 2014, 43(5): 55-63.
- [6] ROSSI P S, CIUNZO D, RAMANO G. Orthogonality and Cooperation in Collaborative Spectrum Sensing through MIMO Decision Fusion[J]. IEEE Transaction on Wireless Communications, 2013, 12(11): 5826-5836.
- [7] 袁海英, 胡 瑜. 结合循环平稳特征和自适应双门限检测的频谱感知算法[J]. 计算机辅助设计与图形学学报, 2013, 25(4): 573-577.
- [8] EDELMAN A, RAO N R. Random Matrix Theory[J]. Acta Numerica, 2005, 14(14): 233-267.
- [9] ZENG Yonghong, LIANG Yingchang. Maximum Minimum Eigenvalue Detection for Cognitive Radio[C]// Proceedings of the 18th Annual IEEE International Symposium on Personal, Indoor and Mobile Radio Communications. Washington D. C., USA: IEEE Press, 2007: 1-5.
- [10] 王颖喜, 卢光跃. 基于最大最小特征值之差的频谱感知技术研究[J]. 电子与信息学报, 2010, 32(11): 2572-2574.
- [11] 曹开田, 杨 震. 基于随机矩阵理论的 DET 合作频谱感知算法[J]. 电子与信息学报, 2010, 32(1): 129-134.
- [12] 邹卫霞, 丁 奇, 周 正, 等. 基于特征值极限分布的双门限频谱感知算法[J]. 系统工程与电子技术, 2012, 34(3): 588-591.
- [13] TRACY C A, WIDOM H. On Orthogonal and Symplectic Matrix Ensembles[J]. Communication in Mathematical Physics, 1996, 29(2): 295-327.
- [14] BAI Z D. Methodologies in Spectral Analysis of Large Dimensional Random Matrices, A Review[J]. Statistica Sinica, 1999, 9(3): 611-677.
- [15] JOHNSTONE I M. On the Distribution of the Largest Eigenvalue in Principle Components Analysis[J]. The Annals of Statistics, 2001, 29(2): 295-327.
- [16] PENNA F, GARELLO R. Cooperative Spectrum Sensing Based on the Limiting Eigenvalue Radio Distribution in Wishart Matrices[J]. IEEE Communications Letters, 2009, 13(7): 507-509.

编辑 陆燕菲