

基于自相关函数图特征的频谱感知算法研究

胡国兵¹, 赵敦博², 杨 莉¹, 赵嫔姣¹

(1. 金陵科技学院电子信息工程学院, 江苏南京 211169;

2. 南京邮电大学电子与光学工程学院、柔性电子(未来技术)学院, 江苏南京 210023)

摘要: 现有图域频谱感知算法主要借助于完全图检测, 其性能在低信噪比时不佳. 为此, 本文提出了一种基于自相关函数图域变换的感知算法, 可有效改善低信噪比下的检测性能. 其基本思路为: 将去均值后观测信号的自相关函数通过归一化、量化等环节转换到图域, 在分析图连通性差异的基础上, 将图拉普拉斯阵的零特征值个数作为检验统计量, 以完成对频谱的有效感知. 文中利用受控不等式理论阐明了随机序列分布的随机性、样本数及量化级数与图的连通性之间的相互关系. 仿真结果表明, 在信噪比为-10 dB时, 本文算法的检测概率接近100%, 其性能优于现有图域感知算法, 且计算复杂度适中, 具有较好的应用效能.

关键词: 频谱感知; 图域信号处理; 连通分量个数; 拉普拉斯矩阵; 受控不等式

基金项目: 江苏省高等学校自然科学研究重大项目(No.20KJA510008); 国家自然科学基金项目(No.62101223)

中图分类号: TN957.51

文献标识码: A

文章编号: 0372-2112(2023)05-1327-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20221002

Research on Spectrum Sensing Based on Graphical Feature of the Autocorrelation

HU Guo-bing¹, ZHAO Dun-bo², YANG Li¹, ZHAO Pin-jiao¹

(1. School of Electronic and Information Engineering, Jinling Institute of Technology, Nanjing, Jiangsu 211169, China;

2. College of Electronic and Optical Engineering & College of Flexible Electronics (Future Technology), Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu 210023, China)

Abstract: The conventional graph domain-based spectrum sensing algorithms are mainly depended on checking for the completeness of the graphs, and their performances deteriorate at low signal-to-noise ratio (SNR). Therefore, this paper proposes a spectrum sensing algorithm in cognitive radio (CR) based on the graph domain transformation of the autocorrelation function, which can efficiently improve the performance of detection. Firstly, the autocorrelation function of the observed signal after removing its mean value is converted to the graph domain. Then, based on analyzing the difference in the number of connected components of generated graphs, the number of zero eigenvalues of the graph Laplacian matrix is used as the test statistic to complete the sensing of CR spectrum. Moreover, the relationships between the randomness of random sequence distribution, the number of samples, the number of the quantization levels and the connectivity of the graph are proved using the theory of majorization inequality. The simulation results show that when the SNR is -10 dB, the detection probability of the algorithm is close to 100%, and its performance is better than the existing graph-based sensing algorithms with moderate computational complexity, which accordingly acquired an superior efficacy.

Key words: spectrum sensing; graph signal processing; the number of the connected components; Laplacian matrix; majorization inequality

Foundation Item(s): Key Natural Science Foundation of the Jiangsu Higher Education Institutions of China (No.20KJA510008); National Natural Science Foundation of China (No.62101223)

1 引言

作为一种动态的频谱分配策略, 认知无线电 (Cog-

nitive Radio, CR) 为解决频谱资源匮乏和利用率不足等问题提供了新途径. 而频谱感知是 CR 实现的前提与基

础^[1]. 目前,常用的频谱感知算法可大致分为基于模型驱动^[2-4]和基于数据驱动^[5,6]两大类. 两类算法的本质仍是将观测信号表征为时间序列,进而提取其统计特征用于频谱检测,其处理效果对样本量有一定的依赖,且存在低信噪比(Signal-to-Noise Ratio, SNR)时特征的可分性及稳定性变差等固有缺陷. 造成这一问题的可能原因是现有的信号表示框架中忽略了信号的潜在内在结构特征^[7,8].

近年来兴起的图域信号处理^[9]技术,将信号从传统的时间序列形式转换到图域,借助图的拓扑表示及信号潜在结构特征为CR频谱感知算法设计提供了新思路^[10]. 由于该方法有效利用了信号采样点间的转移信息,且在进行图域变换时对信号样本进行了量化处理,某种程度上有利于对噪声的抑制^[11],从而提高了算法在低SNR下的性能. 现有的图域频谱感知算法主要基于检测图的完全连接性来判决信号的存在性,其特征主要是图拉普拉斯矩阵的次大特征值^[8]、图的总边数特征^[7]及图的GINI系数^[12]等. 该类算法的优点在于,无论是特征提取还是门限选择都可借助图论的完备理论,但也存在很多明显的缺陷,主要体现在:(1)基于完全图的处理框架,通常要求零假设下的噪声可转换成完全图,而备择假设下的观测信号转换成非完全图. 但在很多情况下,如SNR低或者利用自相关函数等其他统计量进行图域变换时,无法满足上述条件.(2)现有基于完全图的检测算法中,图转换的输入信号主要是观测信号的功率谱或时域序列. 当SNR变低时,不同假设下图转换的统计量之间的差异变小. 因此,所生成图的差异也变小,自然会引检测性能的下降.

针对上述问题,本文提出了一种基于非完全图框架的CR频谱感知算法,将信号的时域自相关函数作为图域变换的输入,并通过检验所生成图的连通性特征差异来实现频谱检测. 计算机仿真结果表明:本算法在低SNR条件下具有更好的检测性能,且计算复杂度适中.

2 系统模型

假设受加性高斯白噪声(Additive White Gaussian Noise, AWGN)污染的观测信号 $r(t)$ 表示为

$$r(t) = s(t) + \omega(t) \quad (1)$$

其中,信号分量 $s(t)$ 为

$$s(t) = \sum_{n=0}^{N_c-1} \zeta(n)g(t-nT_0) \quad (2)$$

式(2)中, N_c 为码元个数, T_0 为码元持续时间, $\zeta(n)$ 为第 n 个码元的电平值, $g(t)$ 为持续时间为 T_0 的单位幅度矩形基带脉冲; $w(t)$ 为零均值AWGN,方差为 σ^2 . 观测信号 $r(t)$ 经等间隔采样后,得到其 N 点离散序列:

$$r(n) = s(n) + w(n), n = 0, 1, \dots, N-1 \quad (3)$$

可将频谱感知问题归结为如下的假设检验:

$$\begin{cases} H_0: r(n) = w(n) \\ H_1: r(n) = s(n) + w(n) \end{cases} \quad (4)$$

式(4)表明, H_0 假设下频谱未被占用; H_1 假设下频谱已被占用.

3 随机序列的图域变换

本节将对随机序列图域变换的流程进行简要介绍,并对影响变换后图连通性的因素及其影响机理进行理论分析,以为后续图域检测算法的设计提供依据.

3.1 图转换

假定存在一个由 N_0 个顶点构成的无向简单图 $G(V, E)$,其中, $V = \{v_1, v_2, \dots, v_{\delta}, \dots, v_{N_0}\}$ 是其顶点集合, $E = \{e_{\delta\beta} | (\delta, \beta) \in (Y_{N_0} \times Y_{N_0})\}$ 是其边集合, $Y_{N_0} = \{1, 2, \dots, N_0\}$ 为顶点序号的集合, $e_{\delta\beta}$ 表示连接顶点 v_{δ} 和 v_{β} 的边,且 $1 \leq \delta, \beta \leq N_0$. 对于一个实随机序列 $\chi(\tau)$, $0 \leq \tau \leq N-1$,可按如下步骤进行图转换:

(1) 归一化:定义离散序列 $\chi(\tau)$ 的最大值及最小值分别为

$$\begin{cases} \chi_{\max} = \max_{0 \leq \tau \leq N-1} \chi(\tau) \\ \chi_{\min} = \min_{0 \leq \tau \leq N-1} \chi(\tau) \end{cases} \quad (5)$$

则归一化后的离散序列为

$$U_{\chi}(\tau) = \frac{\chi(\tau) - \chi_{\min}}{\chi_{\max} - \chi_{\min}}, 0 \leq \tau \leq N-1 \quad (6)$$

其中, $0 \leq U_{\chi}(\tau) \leq 1$.

(2) 量化及顶点映射:变换成图之前需要先对序列进行量化,量化级数 N_0 即为图的顶点数.经均匀量化后的序列可表示为

$$Q(\tau) = \begin{cases} \mu + 1, & \frac{\mu}{N_0} \leq U_{\chi}(\tau) \leq \frac{\mu+1}{N_0} \\ N_0, & U_{\chi}(\tau) = 1 \end{cases} \quad (7)$$

其中, $\mu = 0, 1, \dots, N_0-1$. 将图的顶点 v_i 与量化区间 $[0, 1]$ 的特定子区间(量化级)之间按如下规则进行映射:

$$\begin{cases} \left[\frac{\mu}{N_0}, \frac{\mu+1}{N_0} \right) \longleftrightarrow v_{\mu+1} \longleftrightarrow \mu+1 \\ 1 \longleftrightarrow v_{N_0} \longleftrightarrow N_0 \end{cases} \quad (8)$$

(3) 边定义:图的边由量化后序列 $Q(\tau)$ 的相邻样本之间的幅度变化决定. 对于 $\tau = 0, 1, \dots, N-h-1$,其中步长 $1 \leq h \leq N-1$,如果至少存在一次 $Q(\tau) = \delta$ 且 $Q(\tau+h) = \beta$ 的情形,则认为相应的边 $e_{\delta\beta}$ 是连通的,否则就认为这两个顶点间不连通. 通过遍历所有的样本,可以得到相应边集为 E .

3.2 几个重要定义

若某随机序列 $\chi(\tau)$ 经归一化、量化后得到的样本是离散型随机变量,当其样本数无穷时,量化后样本的概率密度可以看作是归一化后样本概率分布的理想区域采样(Area Sampling, AS)^[13],即

$$f_Q(\mu) = \sum_{i=1}^{N_0} \delta(\mu - i\Delta) \int_{(i-1)\Delta}^{i\Delta} f_U(u) du \quad (9)$$

$$= \sum_{i=1}^{N_0} \delta(\mu - i\Delta) q_i^\infty$$

式(9)中, $\Delta = 1/N_0$ 为量化间隔, $q_i^\infty = \int_{(i-1)\Delta}^{i\Delta} f_U(u) du$.

下面将介绍几个与图转换相关的重要定义,便于对后续图转换机理的讨论.

定义 1 顶点概率向量 定义 $\mathbf{q}^\infty = (q_1^\infty, q_2^\infty, \dots, q_{N_0}^\infty)^\top$ 为图 G_q 的顶点概率向量.若样本数有限时,顶点概率向量记为 $\mathbf{q} = (q_1, q_2, \dots, q_{N_0})^\top$,其中 $q_i = I_i(G_q)/N, i = 1, \dots, N_0, I_i(G_q)$ 表示映射到图 G_q 的第 i 个顶点对应的量化样本总数.显然,有 $\lim_{N \rightarrow \infty} q_i = q_i^\infty, i = 1, \dots, N_0$ 成立.

当待转换信号的样本数充分大时,顶点概率向量 \mathbf{q} 可由量化后样本的直方图(Histogram of the Quantized Samples, HQS)近似.

定义 2 转移概率矩阵^[7] 定义转移概率矩阵 $\mathbf{W}^\infty = (w_{ij}^\infty)_{N_0 \times N_0}, i, j = 1, \dots, N_0$,其中 $w_{ij}^\infty = q_i^\infty q_j^\infty$ 表示从顶点 v_i 到顶点 v_j 的转移概率.

若待转换随机序列的样本数 N 趋于无穷,则转移概率矩阵中的元素 w_{ij}^∞ 即为随机样本中对应于的量化级 i 的样本数占总样本数的比值与对应于量化级 j 的样本数占总样本数的比值之积.

定义 3 转移概率向量 转移概率向量可定义为转移概率矩阵 \mathbf{W}^∞ 的向量化,即

$$\boldsymbol{\omega}^\infty = \text{vec}(\mathbf{W}^\infty) = (\boldsymbol{\omega}_1^\infty, \boldsymbol{\omega}_2^\infty, \dots, \boldsymbol{\omega}_{N_0}^\infty)^\top$$

其中, $\text{vec}(\cdot)$ 是矩阵向量化函数, $\boldsymbol{\omega}_i^\infty = q_i^\infty (\mathbf{q}^\infty)^\top, i = 1, \dots, N_0$.

定义 4 概率向量的部分和 令顶点概率向量 \mathbf{p} 和 \mathbf{q} 的前 Ω 项的部分和分别为

$$S_{p_\Omega} = \sum_{i=1}^{\Omega} p_{[i]}, S_{q_\Omega} = \sum_{j=1}^{\Omega} q_{[j]}, i, j \leq \Omega \leq N_0 \quad (10)$$

其中, $p_{[i]}$ 和 $q_{[j]}$ 为经过降序排列后的顶点概率向量元素.

概率向量的部分和可以用来比较概率向量的随机性^[14],即若 $S_{p_\Omega} \leq S_{q_\Omega}, S_{p_{N_0}} = S_{q_{N_0}} = 1$,则 $\mathbf{p} < \mathbf{q}$,称为概率向量 \mathbf{p} 受控于向量 \mathbf{q} ,即概率向量 \mathbf{p} 的随机性大于 \mathbf{q} ,其分布更均匀.

3.3 图连通性的比较

一般而言,对于随机序列 $\chi(\tau)$,按上述步骤进行图

域变换时,影响图连通性的主要因素包括:顶点概率向量的随机性、样本数以及量化级数(即图的顶点数),其中最关键的因素就是顶点概率向量.下面分别对这些因素对图连通性的影响机理进行说明.

定理 1 ^[15] 若存在两组顶点概率向量 \mathbf{p} 和 \mathbf{q} ,其对应的转移概率向量分别为 $\boldsymbol{\omega} = \mathbf{q} \otimes \mathbf{q}, \boldsymbol{\phi} = \mathbf{p} \otimes \mathbf{p}$,其中 \otimes 表示 Kronecker 积.若 $\mathbf{q} < \mathbf{p}$,则 $\boldsymbol{\omega} < \boldsymbol{\phi}$ 也成立.

证明 见文献[15].

定理 1 表明:顶点概率向量间的受控关系对 Kronecker 积运算是保序的.顶点概率向量可看成是归一化样本的 PDF 的理想区间采样,因此可直接用顶点概率向量(或 HQS)的随机性来评估随机序列生成图的连通性,相较于用转移概率矩阵进行分析而言,更加直观、简便.此外,由文献[7]可知,若顶点概率向量越均匀,则对应的随机序列转换成完全图的概率越大,也就意味着图的连通性越强.

定理 2 若独立同分布随机序列 $X(m) \sim f_X(x), 0 \leq m \leq N-1$,其中 $f_X(x)$ 为其概率密度函数,经归一化、均匀量化后的顶点概率向量为 $\mathbf{p} = (p_1, p_2, \dots, p_{N_0})^\top$.对该随机进行图变换,得到顶点数为 N_0 的无向简单图 G_p ,则其平均度是顶点概率向量 \mathbf{p} 的 Schur 凹函数.

证明 图 G_p 的其平均度为^[7]

$$\psi(\mathbf{p}) = E \{ \text{Deg}(G_p) \} = \frac{2}{N_0} E \{ \text{Edg}(G_p) \} \quad (11)$$

$$= \frac{2}{N_0} \sum_{\alpha=1}^{N_0} \sum_{\beta=1}^{N_0} \left[1 - \frac{1}{p_\alpha} \sum_{i=1, i \neq \beta}^{N_0} (\omega_{\alpha i})^{p_\alpha} \right]$$

式(11)中 $\text{Deg}(G_p)$ 及 $\text{Edg}(G_p)$ 分别表示图 G_p 各顶点的度和及图各边数的和.令

$$\varphi_\alpha(\mathbf{p}) = \sum_{\beta=1}^{N_0} \left[1 - \frac{1}{p_\alpha} \sum_{i=1, i \neq \beta}^{N_0} (\omega_{\alpha i})^{p_\alpha} \right] \quad (12)$$

则式(11)可写为

$$\psi(\mathbf{p}) = \frac{2}{N_0} \sum_{\alpha=1}^{N_0} \varphi_\alpha(\mathbf{p}) \quad (13)$$

考虑到 $\omega_{\alpha i} = p_\alpha p_i, i, \alpha = 1, \dots, N_0$,进一步将 $\varphi_\alpha(\mathbf{p})$ 写为

$$\varphi_\alpha(\mathbf{p}) = \sum_{\beta=1}^{N_0} \left[1 - (1 - p_\beta)^{p_\alpha} \right] = \sum_{\beta=1}^{N_0} f(p_\beta) \quad (14)$$

由式(14)可知 $f(p_\beta)$ 是凹增函数,则 $\varphi_\alpha(\mathbf{p})$ 为 Schur 凹函数, $\sum_{\alpha=1}^{N_0} \varphi_\alpha(\mathbf{p})$ 为增函数, $\psi(\mathbf{p})$ 是关于 \mathbf{p} 的 Schur 凹函数^[16].

实际中,还需注意以下几点:

(1) 由定理 2 可知:对于两组具有同样样本数,但服从不同概率密度函数的随机序列 $X \sim f_X(x), Y \sim f_Y(x)$,其顶点概率向量分别为 \mathbf{p} 和 \mathbf{q} ,经图变换分别得到简单图

G_p 及 G_q , 若 $p < q$, 则平均度 $E[\text{Deg}(G_p)] > E[\text{Deg}(G_q)]$.

(2) 根据随机图理论, 若平均度为 0, 则图的连通分量个数最大, 图的连通性最差; 若平均度增加, 则图的连通分量个数减少, 但图的连通性增加. 特别地, 当图的平均度为 $N_0 - 1$ 时, 其连通分量的个数为 1, 此时图是完全图. 而对于非完全图而言, 其连通分量个数必然大于 1^[17,18].

(3) 对于同一随机序列, 当顶点数一定时, 样本数的增加将导致图连通性的增加; 当样本数一定时, 顶点数的增加将导致图的连通性的减少.

4 基于自相关函数图特征的频谱感知算法

4.1 时域自相关函数的图域特性分析

对于观测信号 $r_g(n)$, 先进行去均值处理, 得到零均值的观测信号:

$$x_g(n) = r_g(n) - \bar{r}_g(n), 0 \leq n \leq N-1 \quad (15)$$

其中, $\bar{r}_g(n)$ 为观测信号 $r_g(n)$ 的均值, $g=0$ 代表 H_0 情形, $g=1$ 代表 H_1 情形. 计算 $x_g(n)$ 的自相关函数:

$$C_{xx}^g(m) = \begin{cases} \sum_{n=0}^{N-m-1} x_g(n)x_g(n+m), & m \geq 0 \\ C_{xx}^g(-m), & m < 0 \end{cases} \quad (16)$$

式(16)中, $C_{xx}^g(m)$ 为 $x_g(n)$ 的自相关函数, 且有 $-(N-1) \leq m \leq N-1$.

在 H_0 情形下, 观测信号为纯高斯白噪声, 其自相关函数为冲击函数, 转换到图域后图中只有 1 到 2 个顶点是连通的(如图 1(a)所示), 其它均为孤立点, 表明连通分量较多, 图的连通性较弱. 在 H_1 情形下, 观测信号是调制信号和噪声的叠加, 其自相关函数的包络呈现为类似辛克函数、内部存在震荡的对称波形, 其生成图中大多数顶点是连通的, 边数较多, 连通分量个数少, 图的连通性较强(如图 2(a)所示). 因此, H_0 和 H_1 两种情形下, 观测信号自相关函数转换得到图的连通性有较大差异. 而产生这种差异的根本, 在于两种情形下顶点概率向量的随机性不同. 由图 1(b)及图 2(b)可见, 两种不同假设下的顶点概率向量分布存在差异, H_1 下顶点概率向量比 H_0 下的更加均匀; 从图 3 中也可看出: H_0 下的顶点概率向量 p 的部分和大于 H_1 情形下的顶点概率向量 q 的部分和, 即有 $q < p$. 因此, 根据定理 2, q 对应生成图的连通性大于 p 对应的生成图; 相应地, 其连通分量的个数也更多. 简言之, 通过自相关函数生成图的连通分量个数特征来设计频谱感知算法是一个合理的选择.

4.2 图的连通分量个数特征

由上文的分析可知: 对于 H_0 情形下观测信号的生成图, 因其中只有少数顶点是连通的, 其他的顶点都是




图 1 H_0 下观测信号自相关函数的图域变换

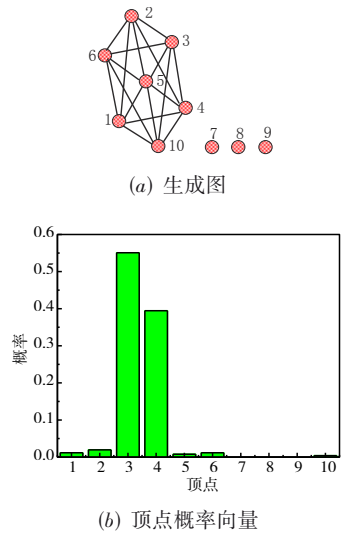


图 2 H_1 下观测信号自相关函数的图域变换




图 3 两种不假设下顶点概率向量间的受控关系

孤立点, 故其连通分量的个数较多; 而对于 H_1 情形下观测信号转换成的图中, 多数顶点是连通的, 只有少数的顶点是孤立点, 故其连通分量的个数较少. 因此, 采用连通分量个数特征作为检测统计量能够有效区分信号的有无.

定理 3^[19] 对于一个仅有非负权重的无向简单图 G , 其拉普拉斯矩阵零特征值的个数(或重数)与图 G 的连通分量个数相等.

证明 见文献[19].

定理 3 的意义在于: 可将图的连通分量个数估计转化对图拉普拉斯矩阵零特征值个数的检测. 于是, 本文提出的频谱存在性检测的判决规则为

$$D = \begin{cases} H_0, & \text{if } N_{ze} \geq \eta_L \\ H_1, & \text{else } N_{ze} < \eta_L \end{cases} \quad (17)$$

其中, D 为判决结果, N_{ze} 为图拉普拉斯矩阵零特征值的个数, η_L 为判决门限.

图 4 所示为两种情形下图拉普拉斯矩阵零特征值的个数 N_{ze} 在不同 SNR 下的对比示意图. 仿真中, 码元速率为 2 kbaud, 载波频率为 800 kHz, 过采样因子为 50, 样本点数为 256 点, 量化级数为 10, SNR 为 -13 dB ~ -2 dB, 每种 SNR 下零特征值个数 N_{ze} 都是 1 000 次仿真的均值. 由图可见: (1) H_0 情形下图拉普拉斯矩阵零特征值个数的均值一直稳定在 9, H_1 情形下图拉普拉斯矩阵零特征值个数的均值都小于 9, 且随 SNR 增大而减小; (2) 随着 SNR 的增大, 两种情形下图拉普拉斯矩阵零特征值个数差异也变大. 上述仿真结果印证了前述的分析结论.




图 4 图拉普拉斯矩阵零特征值个数的均值

综上所述, 本文所提出的基于自相关函数图域变换的频谱感知算法的步骤可归纳如下:

- (1) 对观测信号 $r(n)$ 做去均值处理, 得到零均值的观测信号 $x(n)$;
- (2) 计算 $x(n)$ 的自相关函数 $C_{xx}(m)$;
- (3) 将自相关函数 $C_{xx}(m)$ 转换为具有 N_0 个顶点的图 G ;
- (4) 计算反映图 G 的拉普拉斯矩阵零特征值的个数 N_{ze} , 并与设定的门限 η_L 比较. 若 $N_{ze} > \eta_L$, 则判为 H_0 , 否则判为 H_1 .

5 仿真与性能分析

5.1 仿真条件

除非另有说明, 仿真的条件为: H_0 情形下观测信号

为高斯白噪声, H_1 情形下观测信号为受到高斯白噪声污染的 BPSK 调制信号, 样本点数 $N=256$, 码元速率 $R_b=2$ kbaud, 载波频率 $f_c=800$ kHz, 过采样因子为 30, 采样频率 f_s 为 6 MHz, 化级数 $N_0=10$, 门限 $\eta_L=8$. 每种条件下的仿真次数为 1 000 次. 仿真中使用两种指标来衡量算法的统计性能, 即检测概率和接收机工作曲线^[20] (Receiver Operating Characteristic Curve, ROC). 检测概率用于考察算法在不同条件下的检测性能, 而 ROC 用于比较本算法与其他文献算法的性能.

5.2 SNR 变化对性能的影响

图 5 所示为不同 SNR 条件下本文算法的检测概率变化情况. 由图可见, 随着 SNR 的增大, 本算法的检测概率也随之提高. 其原因在于: 如图 4 所示, 在样本点数一定时, 随着 SNR 的增大, H_0 情形下和 H_1 情形下拉普拉斯矩阵零特征值个数之间距离在增大, 从而更有利于区分两种不同假设, 从而提高了检测性能.




图 5 SNR 变化对本文算法性能的影响

5.3 量化级数变化对性能的影响

图 6 所示为不同量化级数条件下本文算法的检测概率与 SNR 的关系. 如图所示, 当 SNR 较高时, 量化级数对本算法的检测概率基本没有影响; 当 SNR 较低时, 过大或过小的量化级数均不利于检测. 其原因在于: 样本点数一定时, 过少的量化级数会使两种假设下图的连通分量个数都减少, 难以有效检测信号; 类似地, 过多的量化级数会使两种情形下图的连通分量个数都增加, 从而导致算法的检测性能下降.




图 6 量化级数对本文算法性能的影响

5.4 性能对比与分析

本节将本文算法与现有的图域频谱感知算法(即基于完全图检测的极差图法^[12],不分组法^[8]及总边数检测法^[7])与正态性检测法(基于JBtest检测)^[21]等从检测性能与计算复杂度两个方面进行了性能仿真与对比.为便于比较,仿真条件与文献[7]中的设置相同.

(1) 检测性能比较

图7所示为信道为AWGN时,不同SNR及样本点数下,本文算法与其他四种现有算法的ROC对比示意图(SNR=0 dB, $N=100$).由图可见,本文算法性能均优于其他算法.原因在于:相对于已有基于完全图检测的极差图法及总边数检测法,本算法选择时域信号的自相关函数作为图转换器的输入,由于两种假设下观测信号的自相关函数的形状存在很大差别,导致所生所图的连通性也差别明显,且这种差别在低SNR时仍有较好的鲁棒性,从而提高了算法的检测性能.相较而言,现有三种基于完全图检测的图域频谱感知算法中,不分组法与极差图法均以观测信号的功率谱作为输入,当SNR变低时,两种假设下的功率谱差异变小,导致其生成图均为完全图,难以检测.




图7 本算法与现有算法的ROC对比

(2) 计算复杂度比较

本节对算法复杂度分析的基本依据是,一次复数乘法需要6次浮点运算,一次复加需要2次浮点运算^[22].对于三类图域检测方法,其主要计算复杂度主要体现在图域变换前的预处理、图变换及之后的特征提取环节中.表1所示为五种算法的计算复杂度阶数估计及完成一次仿真所需的平均时间.表中每种算法的运算时间均为1000次仿真后求平均所得,仿真条件与图7相同.极差图法需对功率谱进行分组处理, L 表示分组数;总边数法所需的高斯逆累积分布函数的计算涉及到误差函数的计算,需计算无穷积分.其复杂度相对较高,且难以显式表达,权记为 C_1 ;正态性检验法在计算 p 值时,需要通过蒙特卡洛法进行确定,从仿真过程来看,占据一定的运算时间.但其复杂度阶数不易进行显式表达,权记为 C_2 .由表可见,在相同条件下,本文算法的运算时间约为不分组方法的2.5倍,约为极差

图法的3.6倍,约为正态性检测法的45%,总边数检测法的70%.综上,从检测性能与时间复杂度两方面看,本算法的综合效能更佳.

表1 算法的复杂度对比

算法	复杂度	平均运算时间/ms
极差图法	$O(N \log_2 N + L^2 + N_0)$	0.225 15
自相关图法	$O(N^2 + N^2 + N_0^3)$	0.807 79
不分组法	$O(N \log_2 N + N^2 + N_0^3)$	0.328 32
总边数检测法	$O(N + N^2 + N_0) + C_1$	1.150 4
正态性检测法	$O(N) + C_2$	1.830 5

6 结束语

现有图域频谱感知算法主要基于完全图检测框架,其性能在低信噪比时不佳.本文在分析随机序列图域变换机理的基础上,提出了一种基于观测信号时域自相关函数图域特征的频谱感知算法.仿真结果表明:该算法在低SNR条件下的性能优于现有基于完全图检测的频谱感知算法,且计算复杂度适中.本文算法是建立在非完全图检测基础上,某种意义上突破了现有图域频谱感知算法对完全图检测的依赖,对于拓展图域算法的应用范围,构建高效率、高鲁棒性频谱感知算法具有重要的参考价值.

参考文献

- [1] AWIN F, ABDEL-RAHEEM E, TEPE K, et al. Blind spectrum sensing approaches for interweaved cognitive radio system: A tutorial and short course[J]. IEEE Communications Surveys & Tutorials, 2018, 21(1): 238-259.
- [2] 魏急波, 王杉, 赵海涛. 认知无线网络: 关键技术与研究现状[J]. 通信学报, 2011, 32(11): 147-158.
WEI J B, WANG S, ZHAO H T. Cognitive wireless networks: Key techniques and state of the art[J]. Journal on Communications, 2011, 32(11): 147-158. (in Chinese)
- [3] ZHU Y, LIU J, FENG Z, et al. Sensing performance of efficient cyclostationary detector with multiple antennas in multipath fading and lognormal shadowing environments[J]. Journal of Communications and Networks, 2014, 16(2): 162-171.
- [4] SHARMA S K, CHATZINOTAS S, OTTERSTEN B. Eigenvalue-based sensing and SNR estimation for cognitive radio in presence of noise correlation[J]. IEEE Transactions on Vehicular Technology, 2013, 62(8): 3671-3684.
- [5] BKASSINY M, LI Y, JAYAWEEERA S K. A Survey on machine-learning techniques in cognitive radios[J]. IEEE Communications Surveys & Tutorials, 2013, 15(3): 1136-1159.

- [6] MUTHUKUMAR P B, SAMUDHYATHA B, GURUGOPINATH S. Deep learning techniques for cooperative spectrum sensing under generalized fading channels[C]// Proceedings of the 2022 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET). Chennai: IEEE, 2022: 183-188.
- [7] YAN K, WU H C, BUSCH C, et al. Graph representation of random signal and its application for sparse signal detection[J]. Digital Signal Processing, 2020, 96: 102568-102579.
- [8] YAN K, WU H C, XIAO H, et al. Novel robust band-limited signal detection approach using graphs[J]. IEEE Communications Letters, 2017, 21(1): 20-23.
- [9] MARQUES A G, KIYAVASH N, MOURA J M, et al. Graph signal processing: foundations and emerging directions[J]. IEEE Signal Processing Magazine, 2020, 37(6): 11-13.
- [10] 白玉. 基于图分析的 OFDM 频谱感知技术研究[D]. 桂林: 桂林电子科技大学, 2018.
- [11] WIDROW B, KOLLÁR I. Quantization Noise: Roundoff Error in Digital Computation, Signal Processing, Control, and Communications[M]. Cambridge: Cambridge University Press, 2008.
- [12] 赵敦博, 胡国兵, 杨莉, 等. 一种改进的图域频谱感知算法[J]. 电讯技术, 2022, 62(9): 1292-1300.
ZHAO D B, HU G B, YANG L, et al. An improved graph-based spectrum sensing algorithm[J]. Telecommunication Engineering, 2022, 62(9): 1292-1300. (in Chinese)
- [13] WIDROW B, KOLLAR I, MING C L. Statistical theory of quantization[J]. IEEE Transactions on Instrumentation and Measurement, 1996, 45(2): 353-361.
- [14] MARSHALL A W, OLKIN I, ARNOLD B C. Inequalities: Theory of Majorization and Its Applications[M]. Berlin: Springer, 1979.
- [15] Orus R. Entanglement and majorization in (1+1)-dimensional quantum systems[J]. Physical Review A, 2005, 71(5): 052327-052335.
- [16] MARSHALL A W, OLKIN I. Inequalities: Theory of Majorization and Its Applications[M]. New York: Academic Press, 1979.
- [17] MOHAR B. Some Applications of Laplace Eigenvalues of Graphs[M]. Dordrecht: Springer, 1997.
- [18] ANDERSON JR W N, MORLEY T D. Eigenvalues of the Laplacian of a graph[J]. Linear Multilinear Algebra, 1985, 18(2): 141-145.
- [19] VON LUXBURG U. A tutorial on spectral clustering[J]. Statistics and Computing, 2007, 17(4): 395-416.
- [20] METZ C E. Basic principles of ROC analysis[J]. Seminars in Nuclear Medicine, 1978, 8(4): 283-298.
- [21] LU L, YAN K, WU H C, et al. Novel robust normality measure for sparse data and its application for weak signal detection[J]. IEEE Transactions on Wireless Communications, 2013, 12(5): 2400-2409.
- [22] KARAMI E, DOBRE O A. Identification of SM-OFDM and AL-OFDM signals based on their second-order cyclostationarity[J]. IEEE Transactions on Vehicular Technology, 2015, 64(3): 942-953.

作者简介



胡国兵 男, 1978 年 4 月生, 江苏高淳人. 2011 年于南京航空航天大学获工学博士学位, 现为金陵科技学院电子信息工程学院教授、硕士生导师. 主要从事智能信号处理等方面的研究.

E-mail: s0304152@jit.edu.cn



赵敦博 男, 1996 年 9 月出生, 江苏省宿迁市人, 2022 年在南京邮电大学获得电子与通信工程硕士学位. 目前在 5G 通信领域, 从事物理下行共享信道开发工作.

E-mail: d_beau@163.com



杨莉 女, 1983 年 3 月生, 江苏高淳人. 2008 年毕业于扬州大学电子信息工程学院, 获工学硕士学位, 现为金陵科技学院电子信息工程学院高级实验师, 从事通信信号调制识别方面的研究.

E-mail: yangli691@jit.edu.cn



赵斌姣 女, 1990 年 6 月出生, 黑龙江省哈尔滨市人. 2017 年在哈尔滨工程大学信息与通信工程专业获得博士学位. 现为金陵科技学院电子信息工程学院副教授, 主要研究方向为阵列信号处理、高精度无源测向.

E-mail: zhaopinjiao@hrbeu.edu.cn