

DOI:10.20079/j.issn.1001-893x.220816001

引用格式:吴城坤,王全全,宛汀.一种基于特征值和级联聚类的协作频谱感知方法[J].电讯技术,2023,63(12):1911-1917.[WU C K, WANG Q Q, WAN T. A cooperative spectrum sensing method based on eigenvalue and cascade clustering[J]. Telecommunication Engineering, 2023, 63(12): 1911-1917.]

一种基于特征值和级联聚类的协作频谱感知方法*

吴城坤,王全全,宛汀

(南京邮电大学 通信与信息工程学院,南京 210003)

摘要:为了提高低信噪比(Signal-to-Noise Ratio, SNR)下频谱感知的性能,使用模糊 C 均值(Fuzzy C-means, FCM)和高斯混合模型(Gaussian Mixture Model, GMM),提出了一种基于特征值和级联聚类的协作频谱感知方法。从接收信号的协方差矩阵中提取特征值构造特征向量,通过在三维空间中执行聚类得到信道是否可用的分类模型,此过程无需获得主用户(Primary User, PU)信号以及噪声功率的先验信息,避免了复杂的门限计算。FCM 聚类用于优化 GMM 聚类的初始参数,有效解决了在低 SNR 下 GMM 容易陷入局部最小值的问题。仿真结果表明,该方法降低了 GMM 的收敛时间并提高了模型分类的准确性,与其他主流方法相比能够有效提升频谱感知的性能。

关键词:认知无线电;协作频谱感知;高斯混合模型;级联聚类

开放科学(资源服务)标识码(OSID):



微信扫描二维码
听独家语音释文
与作者在线交流
享本刊专属服务

中图分类号:TN92 文献标志码:A 文章编号:1001-893X(2023)12-1911-07

A Cooperative Spectrum Sensing Method Based on Eigenvalue and Cascade Clustering

WU Chengkun, WANG Quanquan, WAN Ting

(School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: In order to improve the performance of spectrum sensing in low signal to noise ratio (SNR), a cooperative spectrum sensing method based on eigenvalue and cascade clustering is proposed by using Fuzzy C-means (FCM) and Gaussian Mixture Model (GMM). The feature vectors are constructed by extracting the eigenvalues from the covariance matrix of the received signals, and the classification model of whether the channel is available is obtained by performing clustering in three-dimensional space. This process does not need to obtain the prior information of the primary user (PU) signal and the noise power, which avoids the complex threshold calculation. FCM clustering is used to optimize the initial parameters of GMM clustering, which effectively solves the problem that GMM is prone to fall into local minimum in low SNR. Simulation results show that the proposed method both reduces the convergence time of GMM and improves the accuracy of model classification. Compared with other mainstream methods, it can effectively improve the spectrum sensing performance.

Key words: cognitive radio; cooperative spectrum sensing; Gaussian mixture model; cascade clustering

* 收稿日期:2022-08-16;修回日期:2022-10-28
基金项目:国家自然科学基金资助项目(62071245)
通信作者:王全全

0 引言

近年来,随着通信技术的发展,频谱资源的需求量迅速增加,认知无线电(Cognitive Radio, CR)被认为是缓解频谱资源稀缺问题的有效方案^[1]。协作频谱感知(Cooperative Spectrum Sensing, CSS)作为 CR 中的关键技术用于检测主用户(Primary User, PU)信号是否存在,使得次用户(Secundary User, SU)能够获得空闲授权频段的使用^[2]。

传统的频谱感知技术存在许多不足,如能量检测计算复杂且受噪声不确定性影响较大,匹配滤波和循环平稳算法需事先了解 PU 信号和信道响应的先验信息^[3]。对此,基于随机矩阵理论的频谱感知方案被应用于频谱感知^[4],如最大最小特征值之比(Ratio of Maximum and Minimum Eigenvalue, MME)、最大特征值与平均特征值之差(Difference between the Maximum Eigenvalue and the Average Eigenvalues, DMEAE)、最大最小特征值之差(Different of Maximum and Minimum Eigenvalues, DMM)以及最大特征值与协方差矩阵的迹之比(Ratio between Maximum Eigenvalue and the Trace, RMET)等。这类方法属于盲频谱感知,通过对接收信号协方差矩阵提取特征值获得频谱感知的统计特性,无需任何 PU 信号和噪声方差的先验信息。文献[5]利用接收信号的协方差矩阵的最大特征值、迹和所有特征值的几何均值构造了检测统计量,提出了一种新的基于特征值的频谱感知融合算法,相比传统基于特征值的方案有更好的检测性能。文献[6]对传统协方差矩阵的 MME 算法进行改进,依靠奇偶时隙划分,有效实现了机会协作。然而,这些方案在实际中需要计算精准的判决门限。

基于机器学习(Machine Learning, ML)的频谱感知技术避免了判决门限计算的问题^[7]。最近许多研究将基于协方差的频谱感知技术与 ML 相结合,通过对协方差矩阵提取特征值产生相应的训练集,从而获得用于频谱感知的模型。文献[8]使用协方差矩阵生成检验统计量并作为卷积神经网络(Convolutional Neural Network, CNN)的输入,通过设计基于最大后验(Maximum a Posteriori, MAP)概率的成本函数推导了基于似然比的频谱感知方法,但在实践中获得关于 PU 的真实数据标签较为困难。无监督学习无需依赖标签数据,可实现盲频谱感知:例如文献[9]提出了基于 K-means 和高斯混合模型(Gaussian Mixture Model, GMM)的无监督频谱感知技术并使用协方差矩阵的 MME 作为分类器的训练输入;又如文献[10]通过对 IQ 分解后的协方差矩

阵提取特征值,提出并分析了不同统计特性下基于 K-means 聚类的感知方案。为了进一步提高频谱感知性能,在特征值的计算引入了随机矩阵的分解与重组(Decomposition and Reorganization, DAR),通过构造两个协方差子矩阵从理论推导上增加了 SU 的数量^[11]。文献[12]利用协方差矩阵特征值以及 GMM 聚类提高了未校准的多天线场景下频谱感知的性能,但是模型底层参数计算的复杂度较大。将图像分析和频谱感知相结合,通过对 PU 信号映射成的图像提取特征值并进行 K-means 聚类得到分类模型^[13],能够有效提高检测性能,但是该方法需要对图像做较为复杂的处理。

在低信噪比的条件下,初始值的选择会对聚类结构产生极大影响,从而影响模型的分类性能,但上述文献未充分考虑初始值的优化工作。对此,本文提出了一种基于特征值和 FCM-GMM 级联聚类的协作频谱感知方法,在保留盲频谱感知优点的基础上,进一步提高低信噪比下 CSS 的性能。通过从接收信号矩阵中提取特征值构造特征向量,并在三维空间中执行聚类,得到信道是否可用的分类模型,避免门限值的计算。GMM 聚类相比于硬聚类的 K-means 有更加灵活的聚类结构,利用模糊 C 均值(Fuzzy C-means, FCM)算法优化 GMM 聚类的初始参数,能够有效解决在低信噪比下 GMM 容易陷入局部最小值的问题,从而达到提高频谱感知性能的目的。

1 系统模型

图 1 为本文考虑的集中式 CSS 系统模型,假设由 1 个 PU、 M 个 SU 和 1 个融合中心(Fusion Center, FC)组成。SU 负责对 PU 信号的感知并通过报告信道将数据传输 FC。FC 统计所有接收到的数据并对 PU 信号是否存在作出判决,如果 PU 信号不存在,则允许 SU 接入 PU 信道使用。

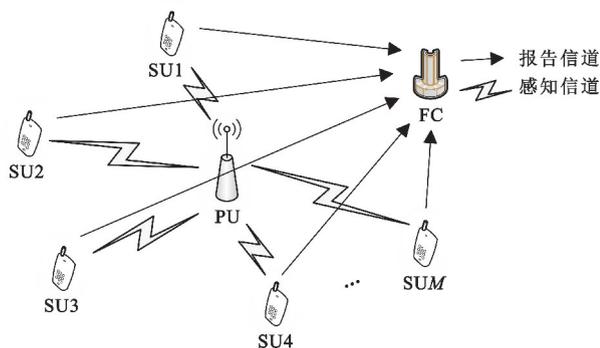


图 1 协作频谱感知模型

频谱感知可以被看成一个二元问题,用 H_0 和 H_1 分别表示 PU 信号不存在和存在,则 SU 在某时刻 t 的接收信号可用 $y(t)$ 表示为

$$y(t) = \begin{cases} n(t), & H_0 \\ s(t)h(t)+n(t), & H_1 \end{cases} \quad (1)$$

式中: $s(t)$ 表示 t 时刻 PU 的信号; $n(t)$ 表示均值为 0、方差为 δ_x^2 的加性高斯白噪声;PU 信号和噪声信号独立分布, $h(t)$ 为 SU 在 t 时刻的传输信道增益。

2 构造信号特征向量

用 $y_i = [y_i(1), y_i(2), \dots, y_i(N)]$ 表示在 t 时刻第 i 个 SU 在 1 个时隙 T_s 内接收的信号向量,其中 N 为采样次数,则所有 SU 接收的采样信号集合可用如下的矩阵形式表示:

$$Y = \begin{pmatrix} y_1(1) & y_1(2) & \cdots & y_1(N) \\ y_2(1) & y_2(2) & \cdots & y_2(N) \\ \vdots & \vdots & & \vdots \\ y_M(1) & y_M(2) & \cdots & y_M(N) \end{pmatrix} \quad (2)$$

噪声信号和 PU 信号的统计协方差矩阵分别为

$$R_w = E\{n(t)n^H(t)\}, \quad (3)$$

$$R_s = E\{s(t)s^H(t)\}. \quad (4)$$

式中: $(\cdot)^H$ 表示矩阵的共轭转置。接收信号向量的统计协方差矩阵及其特征分解如下所示:

$$R_y = E\{y(t)y^H(t)\} = U\Lambda U^H. \quad (5)$$

式中: R 为 M 维方阵; U 为特征向量矩阵; $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_M)$ 表示 R 的特征值矩阵,样本协方差矩阵为

$$\hat{R} = \frac{1}{N} Y Y^T = \hat{U} \hat{\Lambda} \hat{U}^H. \quad (6)$$

当 N 趋向于无穷大时,根据弱大数定律, \hat{R} 和 $\hat{\Lambda}$ 趋近于 R 和 Λ ,其中 $R_w = \sigma_w^2 I$, σ_w^2 为噪声信号方差, I 为 M 维单位矩阵。

$$\hat{R} \rightarrow R = \begin{cases} R_w, & H_0 \\ R_w + R_s, & H_1 \end{cases} \quad (7)$$

为了减少信息损失,协方差矩阵的特征向量可由最大特征值 λ_{\max} 、第二大特征值 $\lambda_{\max 2th}$ 以及最小特征值 λ_{\min} 组成^[14]。在这 3 种特征值中, λ_{\min} 不受 PU 信号的影响,是信道可用类的良好代表,而 λ_{\max} 和 $\lambda_{\max 2th}$ 受 PU 信号影响最大,能够较好地代表信道不可用类,则 FC 接收长度为 L 的特征向量集合为 $X = [x_1, x_2, \dots, x_L]$, $l = 1, 2, \dots, L$, 其中第 l 个特征

向量为

$$x_l = [\lambda_{\min}(l), \lambda_{\max}(l), \lambda_{\max 2th}(l)]^T. \quad (8)$$

3 基于特征值和级联聚类的感知方法

本文的频谱感知方法简要框架如图 2 所示,训练向量经过 FCM 聚类,并将初始参数传递给 GMM,通过聚类得到最终的信道分类模型,模型通过对测试向量分类实现频谱感知。

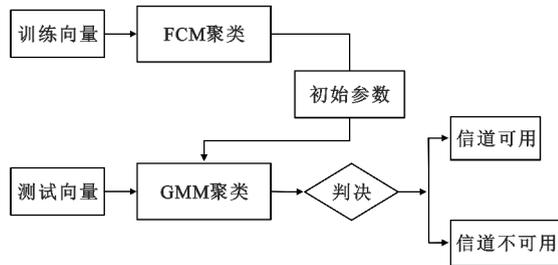


图 2 本文频谱感知方法框架

3.1 训练过程

对于输入的训练特征向量集 $\bar{X} = [x_1, x_2, \dots, x_L]$, FCM 聚类算法的目标函数为

$$J_m = \sum_{i=1}^L \sum_{j=1}^C u_{ij}^m \|x_i - c_j\|^2, 1 \leq m < \infty. \quad (9)$$

式中: $C=2$ 为聚类中心个数; c 为聚类中心集合; m 为模糊指数; u 为隶属度矩阵,满足

$$\begin{cases} u_{ij} \in [0, 1] \\ 0 < \sum_{i=1}^L u_{ij} < L \\ \sum_{j=1}^C u_{ij} = 1 \end{cases} \quad (10)$$

隶属度与聚类中心分别按如下公式更新:

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}}, \quad (11)$$

$$c_j = \frac{\sum_{i=1}^L u_{ij}^m \cdot x_i}{\sum_{i=1}^L u_{ij}^m}. \quad (12)$$

迭代的收敛条件为 $\max_j \{|u_{ij}^{(t+1)} - u_{ij}^{(t)}|\} < \varepsilon$, ε 为收敛阈值,得到的最优解 c 将作为 GMM 的初始值。GMM 以概率来衡量每个数据的隶属类别,其概率密度分布形式为

$$p(x) = \sum_{k=1}^K p(k) p(x|k) = \sum_{k=1}^K \pi_k \mathcal{N}(x | \mu_k, \Sigma_k), \sum_{k=1}^K \pi_k = 1. \quad (13)$$

式中: K 为模型的个数; π_k 表示混合权重; $\mathcal{N}(\mathbf{x}|\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$ 表示第 k 个高斯分布, $\boldsymbol{\mu}_k$ 为均值向量, $\boldsymbol{\Sigma}_k$ 为协方差, D 维的高斯分布形式如下:

$$\mathcal{N}(\mathbf{x}|\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) = \frac{1}{(2\pi)^{D/2}} \frac{1}{|\boldsymbol{\Sigma}_k|^{1/2}} \cdot \exp\left\{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu}_k)^T \boldsymbol{\Sigma}_k^{-1}(\mathbf{x}-\boldsymbol{\mu}_k)\right\} \quad (14)$$

GMM 通过最大似然函数来确定各分布中待定的参数,公式如下:

$$\ln p(\mathbf{X}|\boldsymbol{\pi}, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \sum_{l=1}^L \ln\left(\sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x}_l|\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)\right) \quad (15)$$

最大似然函数通过期望最大化 (Expectation Maximization, EM) 算法求解,具体实现过程如下:

- 1 初始化 $\boldsymbol{\mu}_k = \mathbf{c}_k, \boldsymbol{\Sigma}_k, \pi_k (k=1, 2)$, 计算似然函数初始值;
- 2 期望步骤:

$$\gamma(z_k|x_l) = \frac{\pi_k \mathcal{N}(x_l|\boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{j=1}^K \pi_j \mathcal{N}(x_l|\boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)}$$

- 3 最大化步骤:

$$\boldsymbol{\mu}_k = \frac{1}{L} \sum_{l=1}^L \gamma(z_k|x_l) \mathbf{x}_l$$

$$\boldsymbol{\Sigma}_k = \frac{1}{L} \sum_{l=1}^L \gamma(z_k|x_l) (\mathbf{x}_l - \boldsymbol{\mu}_k)(\mathbf{x}_l - \boldsymbol{\mu}_k)^T$$

$$\pi_k = \frac{L_k}{L}$$

其中, $L_k = \sum_{l=1}^L \gamma(z_k|x_l)$;

- 4 直到参数收敛,否则返回第 2 步。

3.2 感知判决

通过 3.1 节的算法得到 L 个测试向量的相关参数最优解 ($\boldsymbol{\mu}_k^*, \boldsymbol{\Sigma}_k^*, \pi_k^*$), 获得的最佳分类模型可以直接对新的测试向量进行划分。感知判决的数学模型如下:

- 1 输入测试向量 \mathbf{t}
- 2 $\omega = \ln \frac{\pi_1^* \mathcal{N}(\mathbf{t}|\boldsymbol{\mu}_1^*, \boldsymbol{\Sigma}_1^*)}{\pi_2^* \mathcal{N}(\mathbf{t}|\boldsymbol{\mu}_2^*, \boldsymbol{\Sigma}_2^*)}$
- 3 如果 $\omega \geq \alpha$, 则判决为 H_0

其中, 参数 α 用于控制虚警概率 P_f , 检测和判决的过程无需重新训练模型。

3.3 复杂度分析

本文方法的模型训练时间开销包含协方差矩阵 $\hat{\mathbf{R}}$ 、特征值 $\hat{\boldsymbol{\Lambda}}$, 以及 FCM-GMM 聚类的计算, 复杂度分别为 $O(M^2N)$, $O(M^3)$ 和 $O(CdL) + O(2CdL)$, 其中, d 表示维度, C 为聚类中心个数, L 为训练数据长度 ($L \gg N \gg M$)。

将本文方法和其他性能较好的方法复杂度进行对比, 结果如表 1 所示。本文聚类方法与传统 GMM 聚类^[12, 15]相比复杂度更低, 具体取决于训练数据长度 L 的大小, 与 DMM+IQ^[10] 和 DMEAE+DAR^[11] 方法的复杂度相当, 但是本文方法由于使用了 GMM 聚类, 因此具有更好的检测性能。

表 1 不同方法复杂度对比

方法	复杂度
DMM + IQ ^[10]	$O(N^2L) + O(M^3) + O(CdL)$
DMEAE + DAR ^[11]	$O(M^2L) + O(M^3) + O(CdL)$
GMM ^[12, 15]	$O(M^2N) + O(M^3) + O(CdL+CL) + O(2CdL)$
本文方法	$O(M^2N) + O(M^3) + O(CdL) + O(2CdL)$

4 仿真结果与分析

为了展示所提方法的频谱感知性能, 通过 Matlab 仿真分析了本文方法的性能, 并对比其他频谱感知技术。假设 PU 信号为 AM 信号, 信号活跃的概率为 0.5, PU 和 SU 之间为平坦的瑞利衰落信道。噪声为均值为 0、方差为 1 的加性高斯白噪声信号, 并且独立分布。FCM 聚类的 ε 设置为 10^{-3} , 最大迭代步长为 50。为了更好地展示效果, 每一次都提取了 2 000 个信号特征向量用于聚类获得分类模型, 另外提取了 2 000 个信号特征向量用于分析模型的感知性能。

4.1 频谱感知性能分析

图 3 展示了本文方法在信噪比为 -10 dB 下对信号特征向量的聚类效果, SU 数量 $M=5$, 采样点数 $N=100$, 坐标轴 x_1, x_2, x_3 分别为 $\lambda_{\min}, \lambda_{\max}, \lambda_{\max 2th}$ 。图 3 和图 4 分别表示聚类前和聚类后, 蓝色为信道可用类, 红色为信道不可用类。

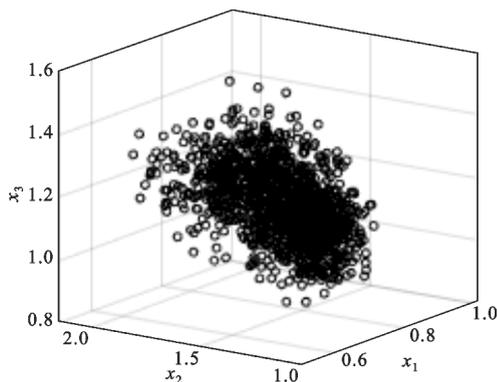


图 3 原始信号特征向量

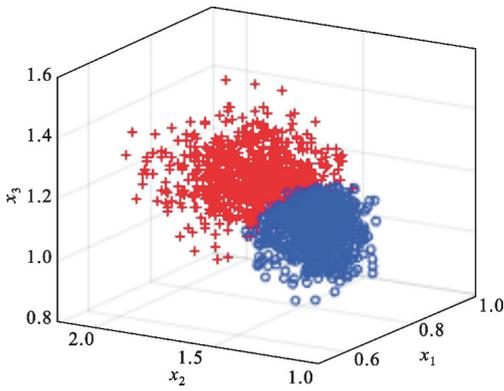


图 4 聚类后的信号特征向量

表 2 给出了本文方法在不同条件参数下的频谱感知性能数值,其中分类准确性用于衡量聚类模型对数据分类的可靠性,模感知性能用接受者操作特征曲线图(Receiver Operating Characteristic, ROC),即检测概率 P_d 关于虚警概率 P_f 的变化图下方的面积(Area Under Curve, AUC)表示,其数值越接近 1,说明感知性能越好。从表 2 中可以看出,在相同 M 和 N 的条件下,分类准确性和检测性能随着信噪比增大而增大,在信噪比固定时, N 和 M 越大,模型感知性能越好,在 $SNR = -10$ dB, $M = 5, N = 200$ 时,分类准确性可达 96%, AUC 达到 0.994。

表 2 频谱感知性能数值

信噪比/dB	分类准确性/%				AUC			
	$M=3, N=100$	$M=3, N=200$	$M=5, N=100$	$M=5, N=200$	$M=3, N=100$	$M=3, N=200$	$M=5, N=100$	$M=5, N=200$
-20	53.2	53.6	54.2	56.1	0.548	0.572	0.554	0.588
-15	60.2	64.0	64.1	70.2	0.645	0.694	0.683	0.771
-10	78.7	87.0	87.8	96.0	0.863	0.955	0.956	0.994

4.2 频谱感知性能对比

图 4 为本文 FCM-GMM 聚类 and 传统 GMM 聚类在处理不同数据量的收敛时间对比图。文献[12]采用传统 GMM 聚类方法,其未对初始值进行优化。仿真设定信噪比为 -12 dB,数据集长度为 2 000~10 000 变化,图中每个点的值都是进行了 5 000 次仿真实验所得的均值,收敛时间通过最大时间归一化。从图 5 中可以看出,本文方法的聚类收敛时间较传统方法缩短约 50%,相比文献[12]的方法有更好的感知实时性。

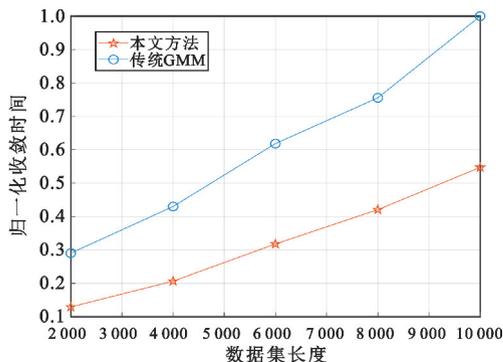


图 5 算法收敛时间对比

聚类在不同信噪比下的信道分类准确性对比,信噪比从 -20~-6 dB 变化, SU 数量 $M=5$, 采样次数 $N=200$ 。从图中可以看出,在信噪比高于 -12 dB 的条件下,两者准确性较为接近,而在信噪比低于 -12 dB 的条件下,本文方法的分类准确性明显优于传统 GMM 聚类,这是因为初始值的优化降低了噪声对模型的影响。

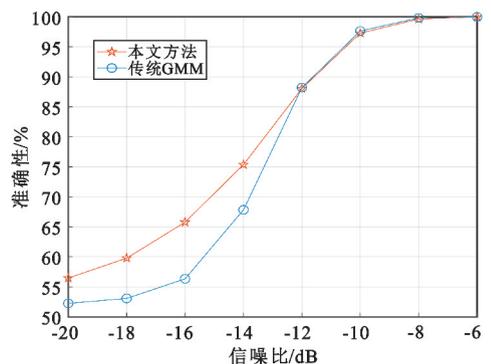


图 6 分类准确性对比

图 7~9 展示了本文方法与其他主流的频谱感知方法的对比,其中 MME、DMEAE、DMM、RMET 采用 IQ 分解技术并通过 K-means 聚类实现频谱感知^[10-11],能量检测算法采用或融合准则。图 7 为不

图 6 为本文 FCM-GMM 级联聚类和传统 GMM

同方法的 ROC 曲线图, SU 数量 $M=5$, 采样次数 $N=200$, 信噪比设定为 -12 dB。可以看出, 本文方法的 ROC 曲线与坐标轴所围成的面积最大, 当虚警概率 P_f 为 0.1 时, 检测概率 P_d 达到 0.85, 与基于 DMM 的 K-means 聚类方法相比提升了 10%。

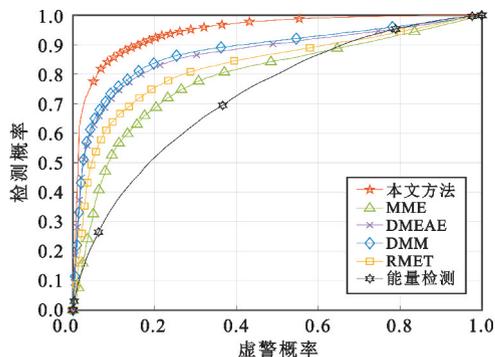


图 7 ROC 曲线

图 8 展示了本文方法与其他方法在不同信噪比下检测概率的对比, 虚警概率 P_f 固定为 0.05, SU 数量 $M=5$, 采样次数 $N=200$, 信噪比从 -20 dB 增加到 -6 dB。从图中可以看出, 本文方法在信噪比为 $-20 \sim -8$ dB 的情况下性能明显优于其他方法, 在 $-8 \sim -6$ dB 区间内性能与基于 DMM 的 K-means 聚类方法和基于 DMEAE 的 K-means 聚类方法较为接近。

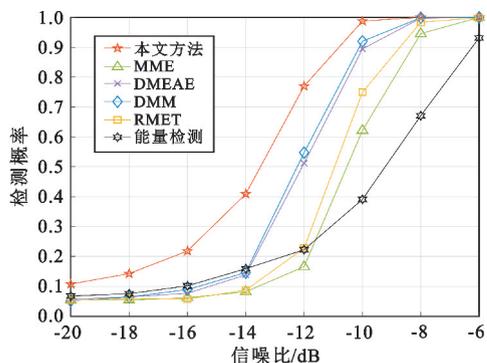


图 8 检测概率与信噪比关系

图 9 为不同方法的 AUC 随信噪比变化图, 虚警概率 P_f 固定为 0.05, SU 数量 $M=5$, 采样次数 $N=200$, 信噪比从 -20 dB 增加到 -6 dB。相同信噪比下与其他方法相比, 本文方法的 AUC 最大, 并且在低信噪比环境下依然有较好的检测性能, 在信噪比为 -12 dB 下, AUC 达到 0.944, 与基于 DMM 的 K-means 聚类方法相比提高了约 10%。

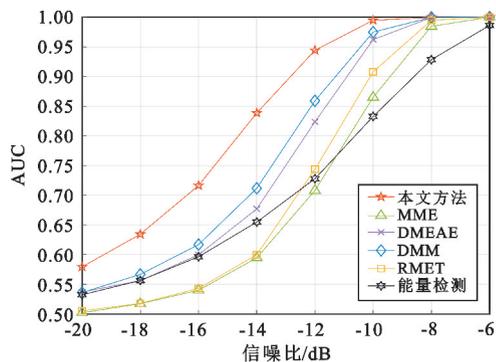


图 9 AUC 与信噪比关系

5 结束语

本文针对低信噪比下的频谱感知问题提出了一种基于特征值和级联聚类的协作频谱感知方法。通过构造关于接收信号矩阵的特征向量, 并在三维空间执行聚类得到信道是否可用的分类模型, 从而实现频谱感知, 其检测和判决的过程无需重新训练模型。仿真结果表明, 本文方法降低了 GMM 聚类的收敛时间并且提高了分类准确性, 在低信噪比条件下依然有较好的检测性能, 具有一定的应用价值。本文还未考虑系统中恶意用户伪造数据的问题, 这会产生异常值从而影响聚类的性能, 后续工作将针对此问题作进一步研究。

参考文献:

- [1] 陈兵, 胡峰, 朱琨. 认知无线电研究进展[J]. 数据采集与处理, 2016, 31(3): 440-451.
- [2] DEY I, DOMENICO C, PIERLUIGI S R. Wideband collaborative spectrum sensing using massive MIMO decision fusion [J]. IEEE Transactions on Wireless Communications, 2020, 19(8): 5246-5260.
- [3] EBRAHIMZADEH A, NAJIMI M, ANDARGOLI S M H, et al. Sensor selection and optimal energy detection threshold for efficient cooperative spectrum sensing [J]. IEEE Transactions on Vehicular Technology, 2015, 64(4): 1565-1577.
- [4] AHMED A, HU Y F, NORAS J M, et al. Spectrum sensing based on maximum eigenvalue approximation in cognitive radio networks [C]//Proceedings of 2015 IEEE 16th International Symposium on a World of Wireless, Mobile and Multimedia Networks. Boston: IEEE, 2015: 1-6.
- [5] 赵文静, 李贺, 金明录. 基于特征值的频谱感知融合算法[J]. 通信学报, 2019, 40(11): 57-64.
- [6] 张无际, 刘顺兰, 包建荣. 基于随机矩阵特征值比的

- 机会协作频谱感知[J]. 电信科学, 2020, 36(2): 61-67.
- [7] 章广梅. 基于 AI 的无线网络感知技术研究综述[J]. 电讯技术, 2022, 62(5): 686-694.
- [8] LIU C, WANG J, LIU X M, et al. Deep CM-CNN for spectrum sensing in cognitive radio[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(10): 2306-2321.
- [9] SOBABE G C, SONG Y H, BAI X M, et al. A cooperative spectrum sensing algorithm based on unsupervised learning [C]//Proceedings of 2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics. Shanghai: IEEE, 2017: 1-6
- [10] ZHANG Y W, WAN P, ZHANG S C, et al. A spectrum sensing method based on signal feature and clustering algorithm in cognitive wireless multimedia sensor networks[J]. Advances in Multimedia, 2017, 2017(4): 1-10.
- [11] WANG Y H, ZHANG Y W, ZHANG S C, et al. A cooperative spectrum sensing method based on a feature and clustering algorithm [C]//Proceedings of 2018 Chinese Automation Congress. Xi'an: IEEE, 2018: 1029-1033.
- [12] MAJUMDER S. A Gaussian mixture model method for eigenvalue-based spectrum sensing with uncalibrated multiple antennas[J]. Signal Processing, 2022, 192: 1-28.
- [13] 岳文静, 刘文博, 陈志. 基于图像 K-means 聚类分析的频谱感知算法[J]. 信号处理, 2020, 36(2): 203-209.
- [14] GIRI M K, MAJUMDER S. Eigenvalue-based cooperative spectrum sensing using kernel fuzzy c-means clustering [J]. Digital Signal Processing, 2021, 111: 1-13.
- [15] CHANDOLA V, VATSAVAI R R, KUMAR D, et al. Analyzing big spatial and big spatiotemporal data: a case study of methods and applications [M]//Handbook of Statistics. Amsterdam: Elsevier, 2015, 33: 239-258.

作者简介:

吴城坤 男, 1998 年生于浙江衢州, 2020 年获学士学位, 现为硕士研究生, 主要研究方向为认知无线电频谱感知。

王全全 男, 1984 年生于江苏连云港, 2012 年获博士学位, 现为副教授, 主要研究方向为电波传播与无线信道分析、石墨烯纳米材料与器件仿真。

宛汀 男, 1981 年生于湖北黄冈, 2012 年获博士学位, 现为副教授, 主要研究方向为无线通信和电磁建模仿真。