

基于无线指纹数据库的认知无线电频谱感知

颜廷秋, 申 滨, 王 欣

(重庆邮电大学 通信与信息工程学院, 重庆 400065)

摘 要: 提出了一种基于无线指纹数据库的频谱感知方案。首先, 在蜂窝认知无线网络(Cell Cognitive Radio Network, CCRN)覆盖的目标地理区域内, 次用户设备(Secondary User Equipment, SUE)收集大量频谱观测数据, 基于各种机器学习算法对频谱观测数据进行处理得到授权频谱上主用户发射机(Primary User Transmit, PUT)的传输模式; 随后, 在 PUT 不同的传输模式下划分地理位置区域, 采用基于空间距离计算的方法获取网格标签, 建立无线指纹数据库; 最后, 有感知需求的次用户设备(Secondary User Equipment, SUE)根据接收到的基站(Base Station, BS)参考信号的到达时间(Time Of Arrival, TOA)估计值来获取其无线指纹, 然后与无线指纹数据库(Wireless FingerPrint Database, WFPD)中的无线指纹(Wireless FingerPrint, WFP)进行匹配确定其地理位置, 并由此确定授权频段的接入标签。仿真结果表明, 本方案在减少对主用户干扰的前提下, 增加了授权频谱的接入机会。

关键词: 频谱感知; 无线指纹数据库; 机器学习; 蜂窝认知无线电

中图分类号: TN92

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.201235

中文引用格式: 颜廷秋, 申滨, 王欣. 基于无线指纹数据库的认知无线电频谱感知[J]. 电子技术应用, 2021, 47(7): 69-73.

英文引用格式: Yan Tingqiu, Shen Bin, Wang Xin. Wireless fingerprint database based spectrum sensing in cognitive radio network[J]. Application of Electronic Technique, 2021, 47(7): 69-73.

Wireless fingerprint database based spectrum sensing in cognitive radio network

Yan Tingqiu, Shen Bin, Wang Xin

(School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: This paper proposes a spectrum sensing scheme based on wireless fingerprint database. Firstly, in the target geographic area covered by the cellular cognitive radio network(CCRN), the secondary user equipment(SUE) collects a large number of spectrum observation data, and processes the spectrum observation data based on various machine learning algorithms to obtain the transmission mode of primary user transmit(PUT) on the authorized spectrum. Then, in the different transmission modes of put, the geographic location area is divided, and the grid label is obtained based on the spatial distance calculation method, and the wireless fingerprint database is established. Finally, the secondary user equipment (SUE) with sensing needs obtains its wireless fingerprint according to the time of arrival(TOA) estimation of the base station(BS) reference signal, and then compares it with the wireless fingerprint in the wireless fingerprint database(WFPD) to determine its geographical location, and thus to determine the access tag of authorized frequency band. Simulations verify that the proposed scheme increases the spectrum access opportunity under the premise of minimizing the interference to the primary user.

Key words: spectrum sensing; wireless fingerprint database(WFPD); machine learning; cell cognitive radio

0 引言

传统频谱感知算法存在很大的局限性^[1-4], 而当前机器学习算法在频谱感知中广泛应用^[5-6]。基于此现状, 本文提出了基于无线指纹数据库的频谱感知方案。本方案中, 首先利用机器学习的方法对 CCRN 区域内收集的频谱观测数据进行处理, 从而获取该区域内的 PUT 联合传输模式信息; 然后在 PUT 联合传输模式确定且 PUT 位置已知的情况下, 以活跃 PUT 为中心划分地理区域, 基于空间距离的算法确定不同网格的频谱可用性标

签; 最后将 PUT 的联合传输模式信息和频谱可用性信息存储在数据库中。有感知需求的 SUE 可以借助存储在无线指纹数据库中的信息和数据, 轻松地作出频谱决策。无线指纹数据库的方案实现了认知无线电中频谱感知即插即用的需求, 其划分地理区域的方式使得 SUE 可以获得更多的潜在频谱接入机会。仿真结果显示, 本方案能有效地满足频谱感知的需求。

1 系统模型

考虑在 CCRN 中, 存在若干个 SUE 和 N 个 PUT 以及

K 个在 F_1 频段上为 SUE 服务的基站,其分散在 CCRN 区域内。为了获取 CCRN 中不同位置的频谱机会,将 CCRN 的目标地理区域划分为具有相同大小的 Q 个网格,CCRN 中的任何 SUE 都可以处于其中特定的网格内。假设 K 个 BS 在 CCRN 中的 F_1 上连续运行,同时在同一地理位置区域内, N 个 PUT 在 F_2 频段上与 PU 接收机通信。当 SUE 通过 F_1 频段与第 k 个 BS 进行通信时,第 q 个网格中的 SUE 接收信号为:

$$\bar{y}_{qk}(i) = \sqrt{P_k} \bar{h}_{kq} \bar{S}_k(i) + \sum_{j=1, j \neq k}^K \sqrt{P_j} \bar{h}_{jq} \bar{S}_j(i) + N_q(i) \quad (1)$$

在 CCRN 中,PUT 的工作状态可以标记为 On 和 Off 两种状态,因此网络中总共存在 2^N 个 PUT 联合传输模式,将其表示为 $S_m = \{s_1^{(m)}, s_2^{(m)}, \dots, s_N^{(m)}\}$,其中, $m \in \{0, 1, \dots, 2^{N-1}\}$ 。则 PUT 在第 m 个传输模式下工作时,第 q 个 SUE 接收到的频谱观测信号表示如下:

$$y_{qm}(i) = \begin{cases} \sum_{n=1}^N \sqrt{P_{TX,n}} h_{nq}^{(m)} X_n^{(m)}(i) + N_q^{(m)}(i) & \mathcal{H}_1 \\ N_q^{(m)}(i) & \mathcal{H}_0 \end{cases} \quad (2)$$

其中, i 为第 m 次感知操作的时间索引, P_{TX} 表示 PUT 发射功率, $X_n^{(m)}(i)$ 代表第 n 个 PU 的第 i 个传输信号, $N_q^{(m)}(i)$ 代表均值为 0、方差为 σ_0^2 的复加性高斯白噪声; \mathcal{H}_0 表示所有的 PUT 处于空闲状态,对应于 JTM 中的 S_0 模式; \mathcal{H}_1 表示至少一个 PUT 处于活跃转状态,对应于 JTM 中的 $S_l, l \in \{1, 2, \dots, 2^{N-1}\}$ 。 $h_{nq}^{(m)}$ 代表第 n 个 PUT 到第 q 个 SUE 的信道增益,可表示为:

$$h_{nq}^{(m)} = \sqrt{PL(\|C_n^{\text{PUT}} - C_q^{\text{SUE}}\|)} \cdot \zeta_n^{(m)} \cdot v_n^{(m)} \quad (3)$$

其中, $C_n^{\text{PUT}} = [C_{n,x}^{\text{PUT}}, C_{n,y}^{\text{PUT}}]$ 表示第 n 个 PUT 的位置, $C_q^{\text{SUE}} = [C_{q,x}^{\text{SUE}}, C_{q,y}^{\text{SUE}}]$ 表示第 q 个 SUE 的位置, $\|\cdot\|$ 表示欧氏距离, $PL(d) = d^{-\alpha}$ 是距离为 d 的传播路径的功率损耗, $\zeta_n^{(m)}$ 表示阴影衰落, $v_n^{(m)}$ 表示瑞利分布中的多径衰落分量。

第 q 个 SUE 接收到的信号能量表示为:

$$Z_q = \sum_{i=1}^{2w\tau} |y_{qm}(i)|^2, \quad q=1, 2, \dots, Q \quad (4)$$

其中, w 是 LFB 带宽, τ 是感知间隔。

由此得出,所有 $Q(O \times P)$ 个网格的能量值矩阵表示为:

$$Y_k = \begin{bmatrix} Z_{11}^{(k)} & Z_{12}^{(k)} & \dots & Z_{1P}^{(k)} \\ Z_{21}^{(k)} & Z_{22}^{(k)} & \dots & Z_{2P}^{(k)} \\ \vdots & \vdots & \ddots & \vdots \\ Z_{O1}^{(k)} & Z_{O2}^{(k)} & \dots & Z_{OP}^{(k)} \end{bmatrix} \quad (5)$$

其中, $Z_{op}^{(k)}$ 表示由式(4)确定的处于 (o,p) 网格位置的 SUE 在第 k 次感知时所获得的频谱观测能量值。矩阵 Y_k 在下一节中将用作 JTM 分类算法的输入。

2 PUT 联合传输模式分类

建立无线指纹数据库需要获取一定时间段内的 JTM 信息,因此本文首先采用机器学习的方法对 PUT 的联合传输模式进行识别。依据式(5),在 CCRN 中,经过大量的 SUE 在长时间内收集的频谱数据,可以得到 PUT 联合传输模式分类的训练数据集 $\{Y_0, Y_1, \dots, Y_K\}$ 以及对应的训练标签 $\{C_0, C_1, \dots, C_K\}$,将其用来训练分类器。接下来是具体算法的分类器训练过程。

2.1 基于 K-means 聚类的分类算法

在本方案中,K-means 聚类算法将训练集中的能量矩阵分为 2^N 类,并且假定每个 JTM 下都有 K 个能量矩阵。与普通的 K-means 聚类算法只对向量进行运算不同,本方案中将测试数据表示为 $O \times P$ 的矩阵 Y_K^* 。假设聚类具有质心,由以下两式可以得到测试数据属于的 PUT 联合传输模式:

$$m_{opt} = \underset{m=0, 1, \dots, 2^N-1}{\operatorname{argmin}} \sum_{i=1}^O \sum_{j=1}^P |Y_K^*(i, j) - A_m(i, j)| \quad (6)$$

$$\hat{S}_k = S_{m_{opt}} = \{\hat{s}_1^{(m_{opt})}, \hat{s}_2^{(m_{opt})}, \dots, \hat{s}_N^{(m_{opt})}\} \quad (7)$$

其中, $A_m(i, j)$ 表示第 (i, j) 个元素索引的第 m 个簇的质心。

2.2 基于 HOG 和 SVM 协同的分类算法

为了实现 PUT 联合传输模式分类,还可以考虑 HOG 和 SVM 协同的方法^[7-8]。在利用训练集和训练标签完成监督方式的模型训练之后,算法先根据输入数据 Y_k 获得其 HOG,然后使用一对多(One-Versus-All, OVA)分类的 SVM,实现多分类的目的。

在获取 HOG 时,采用了大小为 $g \times g$ 的数据处理单元。数据对梯度直方图进行计算,首先将多个数据单元组成一个块,然后对块中的每个单元进行归一化从而得到 HOG 特征。在获取 HOG 特征后,采用 SVM 对数据进行分类处理。在 OVA-SVM 方法中,对 J 类分类目标需要构造 J 个 SVM 二分类模型。具体的处理过程为:第 j 个 SVM 二分类器对第 j 类的数据进行区分,将其对应于 l_j 类的数据的标签设置为 1,而不属于 l_j 类的数据的标签设置为 -1。

2.3 基于卷积神经网络的分类算法

为了获得更高的分类精度,本节考虑基于卷积神经网络(CNN)的分类算法^[9-10]。本节采用的 CNN 由 4 层组成,分别是两个卷积层、池化层、全连接层。表 1 给出了本节采用的 CNN 算法的模型结构和过滤器大小的详细信息。输入为 Y_K^* ,输出为一个对应的 PUT 传输模式类别的标签。

表 1 CNN 分类算法的结构参数

层的类型	输入尺寸	滤波器尺寸	激活函数
卷积层(1)	120×120	3×3×32	ReLU
卷积层(2)	60×60	3×3×64	ReLU
全连接层	14 400×1	1 024 个神经元	Softmax

卷积层和池化层作用是特征提取,是 CNN 模型的核心部分。第一个卷积层的输出表示为:

$$O_1(i,j)=\sigma((W_1^v * Y_K^*)(i,j)+b_1^v), v \in [1, \eta_1] \quad (8)$$

其中, η_1 表示第一个卷积层中卷积滤波器的数量, W_1^v 和 b_1^v 分别表示第一个卷积层中第 v 个卷积滤波器的权重和偏置, $\sigma(\cdot)$ 表示 ReLU 激活函数。上式中两个矩阵的卷积表示如下:

$$(W_1^v * Y_K^*)(i,j)=\sum_i \sum_t Y_K^*(s+i, t+j)W_1^v(s,t) \quad (9)$$

其中, $*$ 表示卷积。类似地,第二层的输出可以表示为:

$$O_2(i,j)=\sigma((W_2^v * O_1)(i,j)+b_2^v), v \in [1, \eta_2] \quad (10)$$

其中, η_2 、 W_2^v 和 b_2^v 表示的含义与式(8)相似。

通过池化层和全连接层后的输出可以表示为:

$$\hat{S}_k=\sigma_1(W_{in} * f(\text{pool}(O_2))+b_{in}I_F) \quad (11)$$

其中, W_{in} 和 b_{in} 分别表示全连接层的权重和偏置, I_F 表示元素全为 1 的 $F \times 1$ 阶列向量, f 表示展平函数, pool 表示池化层, $\sigma_1(\cdot)$ 为 Softmax 激活函数。

3 无线指纹数据库的建立

通过机器学习中的分类器完成 PUT 联合传输模式分类后,CCRN 中 PUT 活跃状态情况由此确定,接下来需要划分地理区域,针对不同区域网格内的 SUE 在不同 PUT 传输模式下的授权频谱接入性进行判断,最后建立无线指纹数据库。

3.1 面向网格的 F_2 频段接入性预测

为了获得更多的频谱机会,同时严格限制对 PUR 产生的干扰,根据 PUT 的传输模式,将目标地理区域划分为深色、浅色和白色区域^[11-12],如图 1 所示。深色区域是以活跃的 PUT 为圆心、半径为 R_1 的 PU 接收机分布区域,PUT 独占此频段,处于此区域的 SUE 严格禁止接入频段;浅色区域是以 PUT 为圆心、内径为 R_1 、外径为 R_2 的环形区域,当 SUE 处于灰色区域时,在预先设定的干扰限制下,机会性地接入频段;白色区域是以 PUT 为圆心、半径为 R_2 的圆外区域,SUE 可以自由地接入频段。

在获得 PUT 的联合传输模式 $\hat{S}_k=\{\hat{s}_1, \hat{s}_2, \dots, \hat{s}_N\}$, 并且

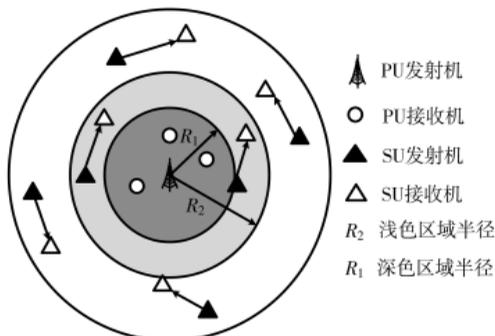


图 1 基于地理区域的 LFB 状态识别

划分地理区域之后,接下来需要对在不同的 PUT 的联合传输模式下,所有网格的 F_2 频段的接入性进行判断。假设活跃 PUT 的位置已知,则可以通过计算网格与先前操作中标识的活跃 PUT 之间的距离来确定不同网格的 F_2 频段可用性,公式表示如下:

$$A_q = \begin{cases} 1 & \sum_{n=1}^N \|C_n^{\text{PUT}} - C_q^{\text{SUE}}\| \cdot \hat{s}_n < \|\hat{S}\|_0 \cdot R_t \\ 0 & \|\hat{S}\|_0 \cdot R_t \leq \sum_{n=1}^N \|C_n^{\text{PUT}} - C_q^{\text{SUE}}\| \cdot \hat{s}_n \leq \|\hat{S}\|_0 \cdot R_p \\ -1 & \sum_{n=1}^N \|C_n^{\text{PUT}} - C_q^{\text{SUE}}\| \cdot \hat{s}_n > \|\hat{S}\|_0 \cdot R_p \end{cases} \quad (12)$$

其中, $\|\cdot\|$ 表示 l_0 范数。 $A_q=1$ 表示严格禁止第 q 个网格内的 SUE 接入授权频段; $A_q=0$ 表示第 q 个网格内的 SUE 接入 F_2 频段可能会对 PU 产生干扰,需要通过其他方式进一步确定能否接入 F_2 频段; $A_q=-1$ 表示第 q 个网格内的 SUE 距离 PUT 足够远,可以自由接入 F_2 频段。 Q 个网格的频谱决策可由此公式确定。

3.2 TOA 地理位置定位

假设已经预先建立好了无线指纹数据库,其结构如表 2 所示,其信息包括 Q 个网格的指纹信息 $WFP_q(q \in \{1, 2, \dots, Q\})$,每个指纹数据包括 TOA 的估计值和与之相对应的第 k 个基站 ID 的组合、不同时刻的 JTM 信息 ($JTM_l, l \in \{1, 2, \dots, 2^N-1\}$),以及特定网格在特定时刻的 JTM 下的授权频谱可用标签 $\text{Label}_{q,l}(q \in \{1, 2, \dots, Q\}, l \in \{1, 2, \dots, L\})$ 。工作原理为:SUE 进入此 CCRN 区域,并且需要获取所在位置的授权频段接入性时,可以通过 TOA 技术对其进行定位获取无线指纹,与无线指纹数据库中存储的无线指纹信息匹配,从而快速做出频谱决策。

表 2 无线指纹数据库结构

网格	WFP1	WFP2	...	WFP q	...	WFP Q
地理位置	$C_1^{(\text{SUE})}$	$C_2^{(\text{SUE})}$...	$C_q^{(\text{SUE})}$...	$C_Q^{(\text{SUE})}$
无线指纹 (TOA)	TOA $_{11}$	TOA $_{21}$...	TOA $_{q1}$...	TOA $_{Q1}$
	TOA $_{12}$	TOA $_{22}$...	TOA $_{q2}$...	TOA $_{Q2}$

授权频谱接入标签	Label $_{11}$	Label $_{21}$...	Label $_{q1}$...	Label $_{Q1}$
	Label $_{12}$	Label $_{22}$...	Label $_{q2}$...	Label $_{Q2}$

	Label $_{1L}$	Label $_{2L}$...	Label $_{qL}$...	Label $_{QL}$

本文采用 TOA 定位算法对 SUE 进行定位^[13]。基于等式(1)中的接收信号,第 q 个 SUE 利用频段 F_1 上本地生成的参考信号来寻找相关输出的峰值作为 TOA。信号相关性表示为:

$$R_{qk}(l)=\left| \sum_{l_1=1}^{L_1} \bar{y}_{qk}(l+l_1) \cdot r_{q, \text{local}}(l_1) \right|^2 \quad (13)$$

其中, $\bar{y}_{qk} = [\bar{y}_{q1}, \bar{y}_{q2}, \dots, \bar{y}_{qL_2}]^T$ 是第 q 个 SUE 接收到的第 k 个 BS 的下行参考信号。 $\bar{y}_{qk}(l+l_1)$ 表示 \bar{y}_{qk} 的第 $(l+l_1)$ 个元素, $\bar{r}_{q,local} = [\bar{r}_{q1}, \bar{r}_{q2}, \dots, \bar{r}_{qL_1}]^T$ 是第 q 个 SUE 生成的信号, $\bar{r}_{q,local}(l_1)$ 表示第 l_1 个信号样本, L_1 和 L_2 分别为本地参考信号和接收信号长度。

由上述所知, 第 k 个基站参考信号到达第 q 个 SUE 的 TOA 测量结果为:

$$T_{qk} = \frac{1}{F_s} \operatorname{argmax}_l (R_{qk}(l)) \quad (14)$$

其中, F_s 是基站下行信号的抽样频率。

假设第 q 个 SUE 需要感知 F_2 频段, 则它首先将其自身的 TOA 指纹发送给无线指纹数据库。 TOA 指纹是 TOA 的估计值和与之相对应的第 k 个基站 ID 的组合, 例如, 当第 q 个 SUE 的无线指纹与无线指纹数据库中的第 q^* 个无线指纹相匹配时, 可以得出个 SUE 位于第 q^* 个网格内。 公式表示如下:

$$q^* = \operatorname{argmin}_{q' \in \{1, 2, \dots, Q\}} \beta_{q'} = \operatorname{argmin}_{q' \in \{1, 2, \dots, Q\}} \sqrt{\sum_{k=1}^K [T_{qk} - FP_{q'}(k)]^2} \quad (15)$$

其中, $\beta_{q'}$ 是 TOA 估计误差的平方根, q^* 是与第 q 个 SUE 测量结果最匹配的指纹的索引, $FP_{q'}(k)$ 表示第 k 个指纹特征值。 另外, 式(15)需要 $\beta_{q'} < \varphi$, $q' \in \{1, 2, \dots, Q\} / q^*$, φ 是阈值, 表示在 SUE 定位过程中的最大错误概率。 如果 $\beta_{q'} > \varphi$, 则第 q 个 SUE 无法找到其对应的网格, 需要通过重新获取指纹。

4 仿真及分析

仿真假设目标地理区域中存在 $P=3$ 个 PUT, 即 PUT 的联合传输模式有 $2^3=8$ 种, 其位置分别设置为: $C_1^{\text{PUT}} = [2\ 000, 2\ 000]^T$, $C_2^{\text{PUT}} = [-2\ 500, 1\ 000]^T$, $C_3^{\text{PUT}} = [-500, -1\ 000]^T$ 。 将 CCRN 覆盖的目标区域划分为 14 400 个大小为 $100\text{ m} \times 100\text{ m}$ 的网格。 带宽为 5 MHz, 感知间隔为 $100\ \mu\text{s}$, 传播路径功率损失参数为 4, 衰落因子为 6 dB。 算法描述的参数, 在 HOG+SVM 中 $g=8, g=16$; 训练集数量为 1 840, 测试集数量为 18 400。 在仿真中, 考虑了 SUE 在网格区域内分布的两种情况, 即均匀间隔分布和全网格分布, 分别表示 11.1% 和 100% 网格内的 SUE 用于频谱观测数据收集, 具体的算法分类准确性如图 2、图 3 所示。

图 2 表示在 CCRN 中 SUE 均匀分布的情况下 PUT 联合传输模式分类的准确性, 由仿真图可知, 相比于传统的高斯混合模型^[14]和 AdaBoost 算法^[15], 本文采用的 3 种算法的分类准确性更好。 图 3 表示收集了区域内所有 SUE 的频谱观测数据的情况下分类算法的精度。 仿真显示, 在高功率的情况下, CNN 和 K-means 聚类算法能达到约 100% 的分类精度, CNN 的收敛速度是最快的。

图 4 表示在不同 JTM 下, 传统能量检测方案与划分地理区域的方案增加的授权频谱接入网格的数量。 由于

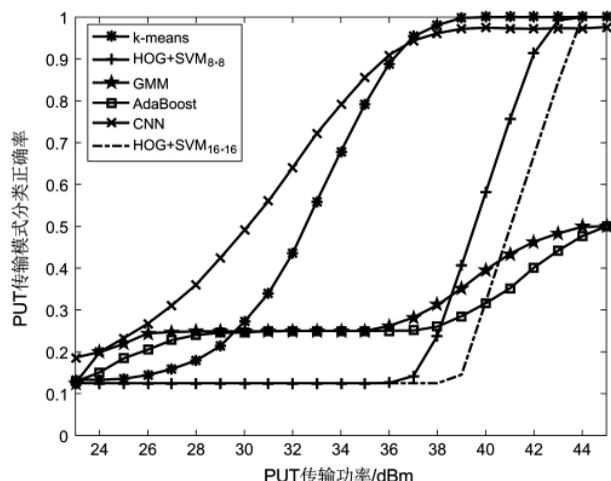


图 2 均匀分布的 SUE 收集的频谱观测值的 JTM 分类算法的准确性

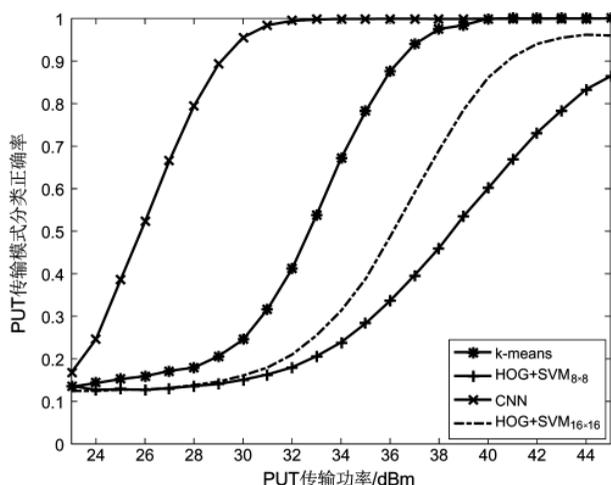


图 3 全部网格内 SUE 收集的频谱观测数据的 JTM 分类算法准确性

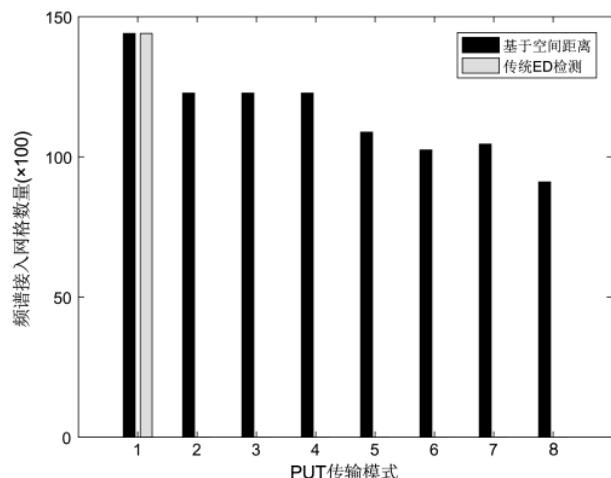


图 4 不同 JTM 下, 增加的授权频谱接入网格的数量

传统能量检测频谱感知方案当且仅当在检测中将 CCRN 中的所有 PUT 都确定为不活动时才使 SUE 可以访问 LFB, 这等同于 JTM 为 S_0 时, 因此在 2^N 个 JTM 下存在大量频谱机会浪费。 与此相反的是, 采用本文提出的划分地理区域的方案, 当 CCRN 中的 PUT 处于活动状态时, SUE

仍然有机会访问 F_2 频段,从而提高了频谱利用率。

图 5 表示对有感知需求 SUE 采用 TOA 定位时的定位的准确性。仿真采用了 4 个基站,基站坐标分别为 $C_1^{BS}=[0,0]$, $C_2^{BS}=[500,0]$, $C_3^{BS}=[500,500]$, $C_4^{BS}=[0,500]$, 仿真随机选取了 20 个 SUE 在理想情况下来进行定位测试, 仿真显示 TOA 定位算法在理想情况下具有较高的定位精度,定位误差远远小于网格的大小,有助于 SUE 作出快速准确的频谱决策。

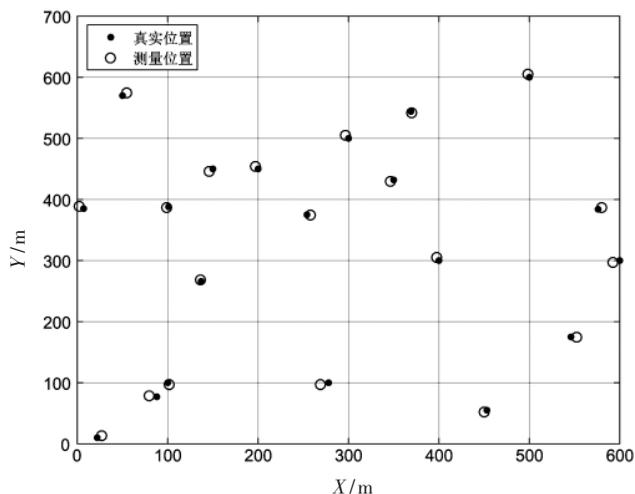


图 5 基于 TOA 定位算法进行 SUE 定位的准确性

5 结论

本文提出了一种基于无线指纹数据库的新型频谱感知方案。仿真结果表明,在对 PUT 联合传输模式分类过程中,不同的机器学习分类算法能够达到较高的精度,划分地理区域的方法与传统算法对比,该方法显著增加了频谱利用率;另外,TOA 定位算法对 SUE 的定位也有着较高的精度,能很好地满足 SUE 的频谱决策需求,达到即插即用的目的。但是,本文只考虑了当 PUT 位置已知情况下的频谱感知问题,PUT 位置未知的情况还需要进一步研究。

参考文献

- [1] ALI A, HAMOUDA W. Advances on spectrum sensing for cognitive radio networks: theory and applications[J]. IEEE Communications Surveys & Tutorials, 2017, 19(2): 1277-1304.
- [2] ZHANG W, MALLIK R K, LETAIEF K B. Cooperative spectrum sensing optimization in cognitive radio networks[C]. 2008 IEEE International Conference on Communications, 2008: 3411-3415.
- [3] MOSLEH S, TADAION A A, DERAKHTIAN M. Performance analysis of the neyman-pearson fusion center for spectrum sensing in a cognitive radio network[C]. IEEE EUROCON 2009, 2009: 1420-1425.
- [4] 栾红志, 李鸥. 一种高效的协作频谱感知架构[J]. 电子与信息学报, 2014, 36(5): 1158-1163.
- [5] THILINA K M, CHOI K W, SAQUIB N, et al. Machine

learning techniques for cooperative spectrum sensing in cognitive radio networks[J]. IEEE Journal on Selected Areas in Communications, 2013, 31(11): 2209-2221.

- [6] Li Zan, Wu Wen, Liu Xiangli, et al. Improved cooperative spectrum sensing model based on machine learning for cognitive radio networks[J]. IET Communications, 2018, 12(19): 2485-2492.
- [7] LEE S, BANG M, JUNG K, et al. An efficient selection of HOG feature for SVM classification of vehicle[C]. 19th IEEE International Symposium on Consumer Electronics, Spain, 2015: 1-2.
- [8] LAOPRACHA N, THONGKRAU T, SUNAT K, et al. Improving vehicle detection by adapting parameters of HOG and kernel functions of SVM[C]. 18th International Computer Science and Engineering Conference, Thailand, 2014: 372-377.
- [9] BITAR N, MUHAMMAD S, REFAI H H. Wireless technology identification using deep convolutional neural networks[C]. 2018th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications, Montreal, 2017: 1-6.
- [10] MERCHANT K, REVAY S, STANTCHEV G, et al. Deep learning for RF device fingerprinting in cognitive communication networks[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1): 160-167.
- [11] 阮丽华, 李勇, 程伟. 一种空时二维联合频谱感知区域划分方案[J]. 系统工程与电子技术, 2016, 38(5): 1146-1152.
- [12] WEI Z, FENG Z, ZHANG Q, et al. Three regions for space-time spectrum sensing and access in cognitive radio networks[J]. IEEE Transactions on Vehicular Technology, 2015, 64(6): 2448-2462.
- [13] GUVENC I, CHONG C C. A survey on TOA-based wireless localization and NLOS mitigation techniques[J]. IEEE Communications Survey and Tutorials, 2009, 11(3): 107-124.
- [14] THILINA K M, CHOI K W, SAQUIB N, et al. Machine learning techniques for cooperative spectrum sensing in cognitive radio networks[J]. IEEE Journal on Selected Areas in Communications, 2013, 31(11): 2209-2221.
- [15] CHEN S, SHEN B, WANG X, et al. SVM and decision stumps based hybrid AdaBoost classification algorithm for cognitive radios[C]. 2019 21st International Conference on Advanced Communication Technology, 2019: 492-497.

(收稿日期: 2020-12-23)

作者简介:

颜廷秋(1996-), 男, 硕士, 主要研究方向: 认知无线电、机器学习。

申滨(1978-), 男, 博士, 教授, 主要研究方向: 信号处理、MIMO 系统和认知无线电。

王欣(1994-), 女, 硕士, 主要研究方向: 机器学习、认知无线电。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所