

## 基于机器学习主用户发射模式分类的蜂窝认知无线网络频谱感知

申滨\* 王欣 陈思吉 崔太平

(重庆邮电大学通信与信息工程学院 重庆 400065)

**摘要:** 近年来, 基于机器学习(ML)的频谱感知技术为认知无线电系统提供了新型的频谱状态监测解决方案。利用蜂窝认知无线网络(CCRN)中的次级用户设备(SUE)所能提供的大量频谱观测数据, 该文提出了一种基于主用户(PU)传输模式分类的频谱感知方案。首先, 基于多种典型的ML算法, 对于网络中的多个主用户发射机(PUT)的传输模式进行分类辨识, 在网络整体层面上确定所有PUT的联合工作状态。然后, 网络中的SUE根据其所处地理位置或者频谱观测数据, 判断其在当前已判定的PUT发射模式下接入授权频谱的可能性。由于PUT在网络中的实际位置可能事先已知或者无法提前确定, 该文给出了3种不同的处理方法。理论推导与实验结果表明, 所提方案与传统的能量检测方案相比, 不仅改善了频谱感知性能, 还增加了蜂窝认知网络对于授权频谱的动态访问机会。该方案可以作为蜂窝认知无线网络中的一种高效实用的频谱感知解决方案。

**关键词:** 蜂窝认知无线网络; 机器学习; 频谱感知; 支持向量机; 卷积神经网络

中图分类号: TN911

文献标识码: A

文章编号: 1009-5896(2021)01-0092-09

DOI: [10.11999/JEIT191012](https://doi.org/10.11999/JEIT191012)

## Machine Learning Based Primary User Transmit Mode Classification for Spectrum Sensing in Cellular Cognitive Radio Network

SHEN Bin WANG Xin CHEN Siji CUI Taiping

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

**Abstract:** In recent years, Machine Learning (ML) based spectrum sensing technology has provided a new solution in spectrum status identification for cognitive radio systems. Based on the large amount of spectrum observations captured by the Secondary User Equipment (SUE) in the Cellular Cognitive Radio Network (CCRN), this paper proposes a spectrum sensing scheme based on the Primary User (PU) transmission mode classification. Firstly, based on a variety of typical ML classification algorithms, the proposed scheme classifies the transmission mode of multiple Primary User Transmitters (PUTs) in the CCRN, and determines the joint operating state of all the PUTs in the CCRN. Subsequently, the SUE evaluates the possibility of accessing the licensed spectrum in the currently determined PUT transmission mode according to its geographical location or spectrum observation data. Since the actual locations of the PUTs in the network may be readily known in advance or unaware of at all, the proposed scheme solves the problem in three different methods. Theoretical derivation and experimental results show that compared with the traditional energy detection scheme, the proposed scheme not only remarkably improves the spectrum sensing performance, but also significantly increases the opportunities of dynamic accessing to the licensed spectrum for the SUEs. The proposed scheme can be used as an efficient and practical spectrum sensing solution in the CCRN.

**Key words:** Cellular Cognitive Radio Network (CCRN); Machine learning; Spectrum sensing; Support vector machine; Convolutional neural network

收稿日期: 2019-12-19; 改回日期: 2020-03-17; 网络出版: 2020-09-16

\*通信作者: 申滨 shenbin@cqupt.edu.cn

基金项目: 国家自然科学基金(61571073)

Foundation Item: The National Nature Science Foundation of China (61571073)

## 1 引言

近年来,无线通信技术的快速发展增加了对频谱资源的需求,而某些授权频段(Licensed Frequency Band, LFB)的低效率使用进一步凸显了频谱稀缺的问题。认知无线电(Cognitive Radio, CR)<sup>[1,2]</sup>通过实时监测LFB的占用状态而实现机会性的次级频谱接入,提高了频谱利用率。为了保证尽可能少地对主用户(Primary User, PU)产生干扰,蜂窝认知无线网络(Cellular Cognitive Radio Network, CCRN)中的次级用户设备(Secondary User Equipment, SUE)只能在LFB尚未感知到任何PU活动时,方可暂时性地获得接入机会。在这个意义上,频谱感知是保证CR系统正常工作及确保PU系统所能承受的最小干扰约束的基础和前提。

目前,现有文献中的频谱感知技术方法大致可以分为4类:(1)基于SUE接收信号幂律统计量的阈值信号检测方法,如能量检测(Energy Detection, ED)。因为仅关注接收信号的能量信息,且在较短的感知时隙内仅能获得有限的频谱观测样本,这类方法面临性能受限的问题;同时,由于噪声功率不确定度的存在,门限校准精度受限,亦可能影响最终性能。(2)协作频谱感知(Cooperative Spectrum Sensing, CSS)算法<sup>[3-5]</sup>。CSS算法利用多个SUE接收信号副本的空间分集特性,获得更高的频谱感知准确性及可靠性。然而,多数CSS方案的具体实现往往需要预先具备针对PU信号及无线传播环境的多种先验知识,在现实中有可能难以实现。(3)基于地理位置数据库的频谱监测方法<sup>[6,7]</sup>。此类方法依托大时间尺度范围内构建的、基于地理位置的频谱观测数据库,通过对目标LFB的长期观测记录,统计分析PU活动规律。然而,如果完全依赖PU统计活动规律,对于小时间尺度上的PU瞬态活动可能缺乏足够的感知灵敏度和响应速度。(4)基于机器学习分类器的频谱感知(Machine Learning based Spectrum Sensing, MLSS)算法。区别于传统的2阶或者高阶信号检测处理方法,作为一种受大量数据驱动的、富有前景的解决方案,MLSS方法近年来也受到关注和推动<sup>[8-12]</sup>。值得说明的是,上述4种方法目前基本上都还处于依靠各自的工作机制独立完成感知任务的阶段。

考虑到在现实的CCRN中收集大量频谱观测数据的便捷性以及MLSS方案对于数据分类的强大处理能力,为了进一步增加SUE在LFB中的机会性接入可能,同时尽可能抑制SUE对PU接收机的干扰,本文提出一种基于机器学习(Machine Learning, ML)算法的新型频谱感知方案。此方案首先致力于

识别CCRN内存在的多个PU发射机(PU Transmitter, PUT)的发射模式,从而判断CCRN内当前所存在的活跃PUT;然后,网络中的SUE根据其自身与活跃PUT之间的空间位置信息或频谱观测数据,决定其是否可接入LFB频段。

## 2 系统模型

考虑在CCRN中,存在若干个SUE和 $N$ 个PUT。PUT在LFB频段上的工作状态可以标记为On和Off两种,因此,网络中总共存在 $2^N$ 个PUT联合发射状态。令 $\mathbf{S}^{(m)} = [s_1^{(m)}, s_2^{(m)}, \dots, s_N^{(m)}]$ 代表第 $m$ 次感知中CCRN内的 $N$ 个PUT对应的工作状态,其中 $s_n^{(m)}$ 代表第 $n$ 个PUT的发射状态,且 $s_n^{(m)} = 1$ 表示其处于活跃发射状态,否则 $s_n^{(m)} = 0$ 。

将CCRN的地理区域划分为 $Q = O \times P$ 个等面积的网格,每个网格根据距其最近的活跃PUT的距离,可划分到3类不同的区域<sup>[13,14]</sup>。区域1定义为黄色区域:以活跃PUT为圆心,半径为 $D_u$ 的PU接收机分布区域。当SUE位于该区域时,严格禁止其在任何条件下接入LFB进行通信,区域2定义为蓝色区域:以活跃PUT为圆心,半径为 $D_p$ 的圆外区域。位于该区域的SUE距离PU接收机足够远,产生的干扰足够小,SUE可以自由接入LFB进行通信,区域3定义为青色区域:以活跃PUT为圆心,内径为 $D_u$ 、外径为 $D_p$ 的环形带状区域。位于该区域的SUE采用Overlay模式通信,即需要明确检测PU信号是否存在。若SUE判断PU信号存在,则不能接入LFB进行通信,否则可以选择机会接入或者不接入。

在CCRN网络中,假设目标SUE位于第 $q$ 个网格,则其接收的频谱观测信号可以表示为

$$z_q(i) = \sum_{n=1}^N \sqrt{P_{TX}} s_n^{(m)} h_{n,q} X_n(i) + N_q(i) \quad (1)$$

其中, $i$ 为时间索引, $P_{TX}$ 代表PUT发射功率, $X_n(i)$ 代表第 $n$ 个PU的第 $i$ 个传输信号, $N_q(i)$ 代表均值为0、方差为 $\sigma_0^2$ 的复加性高斯白噪声, $h_{n,q}$ 代表第 $n$ 个PUT到第 $q$ 个SUE的信道增益,可表示为

$$h_{n,q} = \sqrt{\text{PL}(\|\mathbf{C}_n^{\text{PUT}} - \mathbf{C}_q^{\text{SUE}}\|)} \cdot \nu_n = \sqrt{\text{PL}(D_{n,q})} \cdot \nu_n \quad (2)$$

其中, $\mathbf{C}_n^{\text{PUT}} = [C_{n,x}^{\text{PUT}} C_{n,y}^{\text{PUT}}]^T$ 代表第 $n$ 个PUT在CCRN中的位置, $\mathbf{C}_q^{\text{SUE}} = [C_{q,x}^{\text{SUE}} C_{q,y}^{\text{SUE}}]^T$ 代表第 $q$ 个SUE的位置, $\|\cdot\|$ 为欧氏距离, $\text{PL}(D_{n,q}) = D_{n,q}^{-\alpha}$ 是第 $n$ 个PUT到第 $q$ 个SUE的传播路径功率损耗, $\nu_n$ 是相对于第 $n$ 个PUT信号的阴影衰落及多径衰落复合因子。

对于第 $q$ 个SUE,其获得的频谱观测能量为

$$Z_q = \sum_{i=1}^{2\omega\tau} |z_q(i)|^2, q = 1, 2, \dots, Q \quad (3)$$

其中,  $\omega$ 为观测信号带宽,  $\tau$ 为感知时间。由此, 得到所有 $Q$ 个网格对应的能量值可表示为矩阵形式

$$\mathbf{Y}_m = \begin{pmatrix} Z_{11}^{(m)} & Z_{12}^{(m)} & \dots & Z_{1P}^{(m)} \\ Z_{21}^{(m)} & Z_{22}^{(m)} & \dots & Z_{2P}^{(m)} \\ \vdots & \vdots & \ddots & \vdots \\ Z_{O1}^{(m)} & Z_{O2}^{(m)} & \dots & Z_{OP}^{(m)} \end{pmatrix}, \quad (4)$$

$$O \times P = Q$$

其中,  $Z_{op}^{(m)}$ 代表由式(3)确定的、CCRN网络 $(o, p)$ 网格位置的SUE在第 $m$ 次感知时所获得的频谱观测能量值。

对应于PUT状态为 $\mathbf{S}^{(m)} = S_i$ 时,  $Q$ 个网格在LFB的可用性标签可以表示为

$$\mathbf{A}_l = \begin{pmatrix} a_{11}^l & a_{12}^l & \dots & a_{1P}^l \\ a_{21}^l & a_{22}^l & \dots & a_{2P}^l \\ \vdots & \vdots & \ddots & \vdots \\ a_{O1}^l & a_{O2}^l & \dots & a_{OP}^l \end{pmatrix}, \quad (5)$$

$$l = 0, 1, \dots, 2^N - 1$$

其中,  $a_{op}^l \in \{1, 0, -1\}$ 分别对应于 $S_i$ 状态下处于 $(o, p)$ 网格位置的SUE严格拒绝接入LFB、允许其机会性接入LFB以及允许其自由接入LFB的3个标签。

在CCRN中, 依靠足够多的SUE在足够长的时间内收集的频谱数据, 可以得到用于PUT发射模式分类的训练数据集 $\Theta_T = \{\mathbf{Y}_1^*, \mathbf{Y}_2^*, \dots, \mathbf{Y}_T^*\}$ 以及对应的标签集 $\mathbf{L}_T = \{L_1^*, L_2^*, \dots, L_T^*\}$ , 其中,  $\mathbf{Y}_t^*$ 对应于式(4)表示的矩阵,  $L_t^* \in \{0, 1, \dots, 2^N - 1\}$ ,  $t = 1, 2, \dots, T$ 。

本文方案将感知过程分为两步。第1步, 通过ML算法获得PUT发射模式的状态标签, 即判断当前来自于真实标签为 $L_m$ 的测试数据 $\mathbf{Y}_m$ 所对应的PUT发射模式 $\hat{L}_m$ ; 第2步, 根据SUE及PUT的地理位置信息或者频谱观测数据, 得到对应于 $L_m$ 模式下的LFB可用性标签 $\mathbf{A}_m \in \{\mathbf{A}_l\}_{l=0}^{2^N-1}$ 。值得说明的是, 本文假设PUT的个数 $N$ 事先已知, 针对PUT的地理位置 $\mathbf{C}_n^{\text{PUT}}$ , 给出了已知及未知两种条件下的解决方法<sup>1)</sup>。

### 3 基于PUT发射模式分类的频谱感知

#### 3.1 PUT传输模式分类

(1) 基于能量值数据模板的PUT模式分类。从简化先验条件和实现复杂度需求的角度考虑, 本小

节提出一种基于能量值数据模板的PUT传输模式分类算法。该算法输入的是当前的能量值观测矩阵 $\mathbf{Y}_m$ 以及预先收集的所有PUT传输模式下的能量值模板矩阵 $\hat{\mathbf{Y}} = \{\mathbf{Y}_0, \mathbf{Y}_1, \dots, \mathbf{Y}_{2^N-1}\}$ 。具体的步骤如算法1所示。

(2) 基于K-means聚类算法的PUT模式分类。作为典型的非监督式机器学习算法, 将K-means聚类算法应用于PUT模式聚类时, 其训练数据集所包含的能量矩阵需分为 $K = 2^N$ 簇。假设每个PUT传输模式都有 $\zeta$ 个能量矩阵作为训练数据, 与一般的K-means聚类算法处理向量数据不同, 本小节使用的训练数据集 $\Theta_T (T = \zeta 2^N)$ 中的训练数据 $\mathbf{Y}_t^*$ 和测试集数据 $\mathbf{Y}_m$ 均为 $O \times P$ 维矩阵。令第 $l$ 簇的簇心用矩阵 $\mathbf{A}_l$ 表示, 则由测试数据 $\mathbf{Y}_m$ 预测的PUT传输模式可由式(6)和式(7)得到。

算法1 基于能量值模板差值的PUT模式分类

---

输入:  $\mathbf{Y}_m, \hat{\mathbf{Y}}, G, \text{阈值}\varphi$   
 输出:  $\hat{\mathbf{S}}^{(m)}$   
 初始化

- (1)  $\mathbf{y}_{m,1} = \text{vec}(\mathbf{Y}_m)$ %矩阵转化为列向量
- (2)  $\mathbf{y}_{m,2} = \text{sort}(\mathbf{y}_{m,1}, \text{descending})$ %降序排列
- (3)  $= \{Z_{x_1, y_1}, Z_{x_2, y_2}, \dots, Z_{x_Q, y_Q}\}$
- (4) 获取行位置索引向量  $\mathbf{x} = \{x_1, x_2, \dots, x_Q\}$ 及
- (5) 列位置索引向量  $\mathbf{y} = \{y_1, y_2, \dots, y_Q\}$
- (6) IF  $(Z_{x_1, y_1} < \varphi) \& (Z_{x_2, y_2} < \varphi) \& \dots \& (Z_{x_G, y_G} < \varphi)$
- (7)  $\hat{\mathbf{S}}^{(m)} = S_0$
- (8) Else
- (9) For  $i = 1 : 1 : G$
- (10) For  $j = i + 1 : 1 : G$
- (11) If  $(|x_i - x_j| < g) \& (|y_i - y_j| < g)$
- (12)  $Z_{x_j, y_j} = 0$
- (13) EndIF
- (14) EndFor
- (15) EndFor
- (16) EndIF
- (17) For  $i = 1 : 1 : G$
- (18)  $\mathbf{h}_1(i) = \text{find}(x_i | Z_{x_i, y_i} \neq 0)$
- (19)  $\mathbf{h}_2(i) = \text{find}(y_i | Z_{x_i, y_i} \neq 0)$
- (20) EndFor

$$(21) \Delta_l = \sum_{i=1}^{|\mathbf{h}_1|} |\mathbf{Y}_m(\mathbf{h}_1(i), \mathbf{h}_2(i)) - \mathbf{Y}_l(\mathbf{h}_1(i), \mathbf{h}_2(i))|$$

$$(22) l_{\text{opt}} = \arg \min_{l=1, 2, \dots, 2^N-1} \Delta_l$$

输出:  $\hat{\mathbf{S}}^{(m)} = S_{l_{\text{opt}}}$

注:  $|\mathbf{h}_1|$ 为集合 $\mathbf{h}_1$ 的势, 即其所包含的所有元素的个数。

---

<sup>1)</sup> 在CCRN中, 由于SUE与其周围的多个蜂窝基站之间的无线链接, 假设SUE的位置信息能够通过相应的定位方法较为精确地获得。

$$l_{\text{opt}} = \arg \min_{l=0,1,\dots,2^N-1} \sum_{i=0}^O \sum_{j=0}^P |Y_m(i,j) - A_l(i,j)| \quad (6)$$

$$\hat{S}^{(m)} = S_{l_{\text{opt}}} \quad (7)$$

其中,  $A_l(i,j)$ 代表第 $l$ 簇的簇心对应于网格 $(i,j)$ 处的能量值。

(3) 基于HOG和SVM协同的PUT模式分类。为了实现PUT传输模式分类, 还可以考虑结合HOG和SVM的方法<sup>[15,16]</sup>。在完成监督方式的模型训练之后, 算法先根据输入数据 $Y_m$ 获得数据单元大小为 $g \times g$ 的梯度直方图, 将多个单元组成一个块, 归一化块中每个单元的梯度得到HOG特征。然后使用一对多(One-Versus-All, OVA)分类的SVM, 实现多分类的目的<sup>[9]</sup>。

(4) 基于卷积神经网络的PUT模式分类。为了进一步提高PUT传输模式分类的准确性, 还可将CNN引入分类判决<sup>[17]</sup>。本文采用的CNN由4层组成, 前两层是卷积层, 接着是池化层、全连接层。具体的模型结构和滤波器尺寸如表1所示。

上述各种PUT模式分类算法所对应的分类准确性, 可通过式(8)衡量

$$\begin{aligned} P_{A,1} &= \mathbb{E}_{m,l}[P(\hat{S}^{(m)} = S_l | \mathcal{H}_l)] \\ &\approx \lim_{M \rightarrow \infty} \frac{1}{M} \sum_{m=1}^M \sum_{l=0}^{2^N-1} P(\mathcal{H}_l) I\{\hat{S}^{(m)} = S_l | \mathcal{H}_l\} \end{aligned} \quad (8)$$

其中,  $\mathbb{E}$ 为数学期望,  $\mathcal{H}_l$ 代表PUT传输模式 $S_l$ 对应的假设,  $P(C)$ 表示事件 $C$ 发生的概率,  $I\{C\}$ 为指示函数, 条件 $C$ 为真时, 其值为1; 条件 $C$ 为假时, 其值为0。

### 3.2 面向网格的LFB接入标签预测

在完成PUT传输模式分类后, CCRN内的PUT活跃状态情况由此确定, 此时需要针对每一个网格进行LFB接入可能性预测。

(1) 基于空间距离计算的网格LFB接入标签预测。通过前述任一算法, 在获得了PUT的传输模式 $\hat{S}^{(m)} = [\hat{s}_1^{(m)}, \hat{s}_2^{(m)}, \dots, \hat{s}_N^{(m)}]$ 后, 当PUT的位置精确已知时, 第 $q$ 个网格内的SUE的授权频段标签, 即 $\hat{a}_q^{(m)}$ , 可以通过式(9)获得

$$\hat{a}_q^{(m)} = \begin{cases} 1, & \sum_{n=1}^N D_{n,q} \cdot \hat{s}_n^{(m)} < \|\hat{S}^{(m)}\|_0 \cdot D_u \\ 0, & \|\hat{S}^{(m)}\|_0 \cdot D_u \leq \sum_{n=1}^N D_{n,q} \hat{s}_n^{(m)} \leq \|\hat{S}^{(m)}\|_0 \cdot D_p \\ -1, & \sum_{n=1}^N D_{n,q} \cdot \hat{s}_n^{(m)} > \|\hat{S}^{(m)}\|_0 \cdot D_p \end{cases} \quad (9)$$

其中,  $\|\cdot\|_0$ 为 $l_0$ 范数。

(2) 基于OVO-SVM的网格LFB接入标签预测。在获得PUT传输模式后, 若PUT的位置完全未知, 则无法根据式(9)中的距离计算判断SUE在CCRN中所属网格的黄蓝青区域属性。此时, 仅能依据PUT当前模式下的能量观测值进行LFB接入标签预测。不同的能量观测值可相应地区分为3类, 选择使用一对一(One-Versus-One, OVO)的SVM实现3分类。

(3) 基于双门限能量检测的网格LFB接入标签预测。在获得PUT传输模式后, 在PUT位置未知的条件下, 根据传统的能量检测算法也能够获得网格的LFB接入标签。具体地, 第 $q$ 个网格中的SUE需要先找到使得网格预测标签-1对应的期望虚警概率为 $P_{FA,1}$ 的检测阈值 $\lambda_{1,q}$ 和使得网格标签+1对应的期望虚警概率为 $P_{FA,2}$ 的检测阈值 $\lambda_{2,q}$ , 其中 $\lambda_{1,q} < \lambda_{2,q}$ 。根据能量检测方法, 第 $q$ 个网格中的SUE可以通过式(10)中的双门限判决得到其对应的LFB接入标签

$$\hat{a}_q^{(m)} = \begin{cases} -1, & Z_q \leq \lambda_{1,q} \\ 0, & \lambda_{1,q} < Z_q < \lambda_{2,q} \\ 1, & Z_q \geq \lambda_{2,q} \end{cases} \quad (10)$$

在获得了面向网格的频谱接入标签预测结果之后, 其精确度可以衡量为

$$\begin{aligned} P_{A,2} &= \mathbb{E}_{m,l,q}[P(\hat{a}_q^{(m)} = a_q^{(m)}, \hat{S}^{(m)} = S_l | \mathcal{H}_l)] \\ &\approx \lim_{M \rightarrow \infty} \frac{1}{M} \frac{1}{Q} \sum_{m=1}^M \sum_{q=1}^Q \sum_{l=0}^{2^N-1} P(\mathcal{H}_l) \\ &\quad \cdot I\{\hat{a}_q^{(m)} = a_q^{(m)}, \hat{S}^{(m)} = S_l | \mathcal{H}_l\} \\ &= \lim_{M \rightarrow \infty} \frac{1}{M} \frac{1}{Q} \sum_{m=1}^M \sum_{q=1}^Q P_{A,1} I\{\hat{a}_q^{(m)} = a_q^{(m)}\} \end{aligned} \quad (11)$$

## 4 数据充分性分析

由前述内容可知, 基于机器学习算法的PUT模式分类需要大量的频谱观测数据, 例如训练数据集 $\Theta_T$ 和测试数据 $Y_m$ , 均应在满足充分的数据获取条件下获得, 即每个网格位置都有相应的SUE提供

表1 CNN分类算法采用的结构参数

层类型	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	14400×1	1024个神经元	Softmax

观测数据。在现实中，这一条件在获取 $\mathbf{Y}_m$ 时不一定能够满足，即由于SUE的空间分布特性，不一定能保证每个网格都有SUE存在并获取频谱观测数据。由于数据充分性的缺失，必然会影响分类判决的性能。

假设SUE在CCRN中的位置分布服从强度为 $\lambda^u$ 的空间齐次泊松点过程，并且每个网格大小相对于CCRN来说足够小，各个SUE在CCRN内的位置分布互相独立。由于CCRN中存在 $Q$ 个网格，将CCRN全部地理区域 $\mathbf{II}$ 划分为 $\mathbf{II} = \cup_{n=1}^Q \Pi_q$ ， $\Pi_q$ 表示归属于第 $q$ 个网格的地理区域，且 $\Pi_q \cap \Pi_{q'} = \emptyset$ ， $\forall q \neq q'$ 。定义CCRN区域总面积为 $|\mathbf{II}|$ ， $\Pi_q$ 的面积为 $|\Pi_q|$ ，则有 $|\mathbf{II}| = \sum_{q=1}^Q |\Pi_q|$ ， $\Pi_q \subset \mathbf{II}$ ， $q = 1, 2, \dots, Q$ 。

令 $A(\Pi_q)$ 表示位于 $\Pi_q$ 区域内的SUE数量，由上述分析，对于任意的 $\Pi_q$ ，有

$$A(\Pi_q) \sim \text{Poisson}(\lambda^u |\Pi_q|) \quad (12)$$

根据空间泊松点过程的性质，有

$$P(A(\Pi_q) = \chi_q) = \frac{e^{-\lambda^u |\Pi_q|} (\lambda^u |\Pi_q|)^{\chi_q}}{\chi_q!} \quad (13)$$

其中， $\chi_q$ 表示分布于网格区域 $\Pi_q$ 内的SUE数目。

对于任意一个SUE，假设其既存在于区域 $\mathbf{II}$ 中，又存在于 $\Pi_q$ 区域内，则此概率为

$$p_q(1, 1) \triangleq P(A(\Pi_q) = 1 | A(\mathbf{II}) = 1) = \frac{|\Pi_q|}{|\mathbf{II}|} \quad (14)$$

其中， $P(\cdot|\cdot)$ 为条件概率。证明过程为

$$\begin{aligned} p_q(1, 1) &= \frac{P(A(\Pi_q) = 1, A(\mathbf{II}) = 1)}{P(A(\mathbf{II}) = 1)} \\ &= \frac{P(A(\Pi_q) = 1, A(\mathbf{II} \setminus \Pi_q) = 0)}{P(A(\mathbf{II}) = 1)} \\ &= \frac{e^{-\lambda^u |\Pi_q|} \lambda^u |\Pi_q| \cdot e^{-\lambda^u |\mathbf{II} \setminus \Pi_q|}}{e^{-\lambda^u |\mathbf{II}|} \lambda^u |\mathbf{II}|} = \frac{|\Pi_q|}{|\mathbf{II}|} \end{aligned} \quad (15)$$

进而可知，在 $A(\mathbf{II}) = \tilde{Q}$ 的情况下，对于 $A(\Pi_q) = \chi_q$ ，其概率为

$$\begin{aligned} p_q(\chi_q, \tilde{Q}) &= P(A(\Pi_q) = \chi_q | A(\mathbf{II}) = \tilde{Q}) \\ &= C_{\tilde{Q}}^{\chi_q} \left( \frac{|\Pi_q|}{|\mathbf{II}|} \right)^{\chi_q} \left( 1 - \frac{|\Pi_q|}{|\mathbf{II}|} \right)^{\tilde{Q} - \chi_q} \end{aligned} \quad (16)$$

其中， $C_{\tilde{Q}}^{\chi_q} = \frac{\tilde{Q}!}{(\tilde{Q} - \chi_q)! \chi_q!}$ 。由式(16)可得

$$\Gamma_q \sim B\left(\tilde{Q}, \frac{|\Pi_q|}{|\mathbf{II}|}\right) \quad (17)$$

其中， $B(\cdot, \cdot)$ 代表二项分布， $\Gamma_q$ 表示在 $A(\mathbf{II}) = \tilde{Q}$ 的条件下， $A(\Pi_q)$ 为 $\chi_q$ ，服从式(16)所示的二项分布。

基于上述分析，在网络区域 $\mathbf{II}$ 中可提供频谱观测数据的SUE总数为 $\tilde{Q}$ 的条件下，对于区域 $\Pi_q$ 中存在SUE的理论概率值定义为

$$\begin{aligned} F_{\chi_q}(\xi | \tilde{Q}) &= P(1 \leq \chi_q \leq \xi | A(\mathbf{II}) = \tilde{Q}) \\ &= \sum_{1 \leq \chi_q \leq \tilde{Q}} C_{\tilde{Q}}^{\chi_q} \left( \frac{|\Pi_q|}{|\mathbf{II}|} \right)^{\chi_q} \left( 1 - \frac{|\Pi_q|}{|\mathbf{II}|} \right)^{\tilde{Q} - \chi_q} \end{aligned} \quad (18)$$

其中， $\xi$ 为同时分布于网格 $\Pi_q$ 内的SUE的数量。由于 $|\Pi_q|/|\mathbf{II}|$ 的值较小，因此， $\xi$ 取值为大于2以上整数的概率相应也很小。

对于SUE空间泊松点分布的具体实现，整个CCRN内满足 $\tilde{Q} = \sum_{q=1}^Q \chi_q$ 。考虑只有在网格区域内分布有SUE的网格，才有可能产生对应于该网格位置的频谱观测数据，并且由于同一网格内的数据相似性，其内部的多个SUE只选取其中一个频谱观测数据上报，因此，数据充分性条件 $\eta$ 可由式(19)衡量

$$\eta = \frac{\sum_{q=1}^Q I\{\chi_q \geq 1\}}{Q} \times 100\% \quad (19)$$

## 5 仿真结果及分析

在本文中，假设目标地理区域中存在 $N=3$ 个PUT，对应 $2^N=8$ 种可能的PUT传输模式种类，且其位置分别为 $\mathbf{C}_1^{\text{PUT}} = [2000, 2000]^T$ ， $\mathbf{C}_2^{\text{PUT}} = [-2500, 1000]^T$ ， $\mathbf{C}_3^{\text{PUT}} = [-500, -1000]^T$ 。将CCRN网络覆盖的 $12 \times 12$  km的区域划分为14400个网格，网格大小为 $100 \times 100$  m，如图1所示。带宽 $w$ 为5 MHz，感知时间 $\tau$ 为100  $\mu\text{s}$ ，传播路径功率损失参数 $\alpha$ 为4，衰落因子为6 dB。算法描述中的参数，基于能量值的PUT传输模式分类中 $G=8$ ， $g=5$ ；在HOG算法中 $g=8$ 或 $g=16$ ；训练集数量 $T$ 为1840，测试

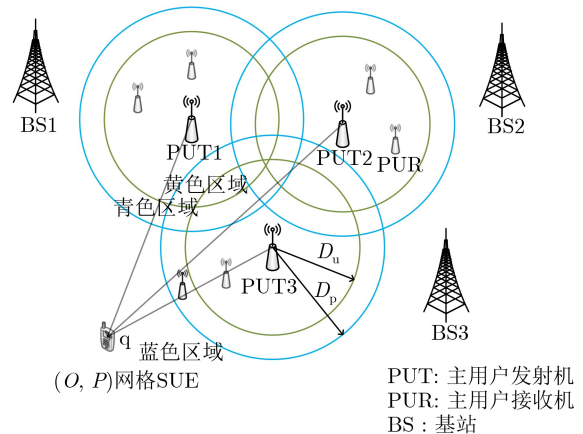


图1 仿真场景图

集数量为18400。在仿真中，考虑SUE在CCRN中的分布有3种情况，即按网格均匀间隔分布、空间泊松点分布以及全网格分布。具体采用的数据充分性条件给出了11.1%, 47.4%, 100% 3种情况。本节给出Matlab环境下的蒙特卡洛仿真结果。

在仿真实验中，假设CCRN中的PUT数目 $N$ 已知。图2(a)为SUE在CCRN中满足均匀间隔分布，且数据充分条件为 $\eta=11.1\%$ 时所对应的PUT传输模式分类正确率。相比传统的高斯混合(mixture-of-Gaussian) 算法[8]和AdaBoost算法[12]，本文提出的CNN以及HOG与SVM结合的算法性能更优。由于PUT的数目假设已知，K-means算法按照 $2^N$ 簇的预设条件进行聚类，在此情况下性能远优于除了CNN之外的其他算法。图2(b)为SUE在CCRN内满足空间泊松点分布，且数据充分条件为 $\eta=47.4\%$ 时所对应的PUT传输模式分类正确率。图2(c)为 $\eta=100\%$ 时的PUT传输模式分类正确率。从图2可以看出，随着数据充分性的满足程度逐步提高，CNN相对于其他算法的性能优势也在大幅度提高，各个算法本身对应的PU传输模式分类准确率也有所提升。

表2给出了在不同数据充分性条件下，各个算法对PUT传输模式分类的准确率。由表2可以看出，在各种算法中，CNN可以获得明显更高的分类准确率。

在完成PUT传输模式分类的基础上，在此进

一步预测网络的LFB接入标签。针对3种不同的网格标签预测算法，都采用了相同的CNN算法作为PUT传输模式分类算法。当 $\{C_n^{PUT}\}_{n=1}^N$ 已知时，在确定了PUT的传输模式后，有LFB接入需求的SUE可根据式(9)所示的与活跃状态PUT之间距离的计算获得LFB的可用性标签，如图3(a)所示， $N=3$ 个PUT，对应了 $2^N=8$ 种可能的PUT传输模式种类。当 $\{C_n^{PUT}\}_{n=1}^N$ 未知时，在获得了PUT传输模式后，SUE需要利用对应于该模式下的OVO-SVM网格分类器获得LFB接入标签预测，如图3(b)所示。图3(c)为使用双门限能量检测方法获得的网格标签分类图。从图3可以看出，使用OVO-SVM方法获得的网格分类更接近理想情况，即图3(a)所示，说明使用OVO-SVM的网格标签预测方案相对于双门限能量检测方案所获得的网格标签预测的准确度更高。值得说明的是，在图3(a)，图3(b)所示的网格标签中，属于黄色区域与青色区域的网格标签预测较为集中连续，可以有效地规避SUE对于这两个区域内的PU所产生的干扰；而图3(c)中的双门限检测算法明显对于黄色区域和青色区域的标签预测有较大的错误率。

在PUT发射功率为43 dBm时，图4(a)和图4(b)分别给出了8种PUT传输模式下的网格LFB接入标签预测分类错误率以及在实际的青、黄区域内的网格发生LFB预测标签分类错误的网格数量。结合图3、

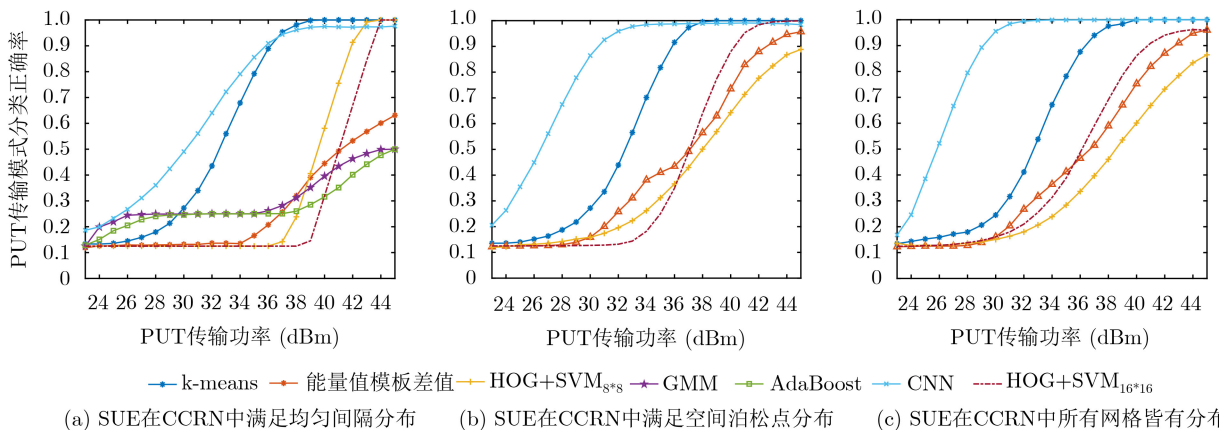




图 2 PUT数量已知时，其传输模式分类准确率

表 2 PUT传输功率为32 dBm时，PUT传输模式分类准确率


算法名称	数据充分性条件		
	11.1%	47.4%	100%
能量值模板差值	0.12	0.26	0.28
K-means	0.42	0.43	0.44
HOG+SVM_8*8	0.12	0.16	0.17
HOG+SVM_16*16	0.12	0.12	0.18
CNN	0.62	0.96	0.99



(a) 根据与活跃PUT之间距离计算获得的网格标签图



(b) 根据OVO-SVM算法获得的网格标签图



(c) 根据双门限能量检测算法获得的网格标签图

图3 传输功率43 dBm时, 8种PUT传输模式下网格标签图

图4可以看出, 在各种PUT传输模式下, OVO-SVM方案相对于双门限能量检测方案在网格LFB接入标签预测分类错误率以及在青、黄区域内发生分类错误的网格数量都显著降低。图4(c)显示了整个CCRN

中所正确判定的可接入LFB的所有网格数量。从图4中可以看出, 相比传统的ED方案只能在PUT传输模式为 $S_0$ 时SUE才可以接入LFB, 本文采用的OVO-SVM和双门限能量检测的方案在 $S_1 \sim S_7$ 传输模式下

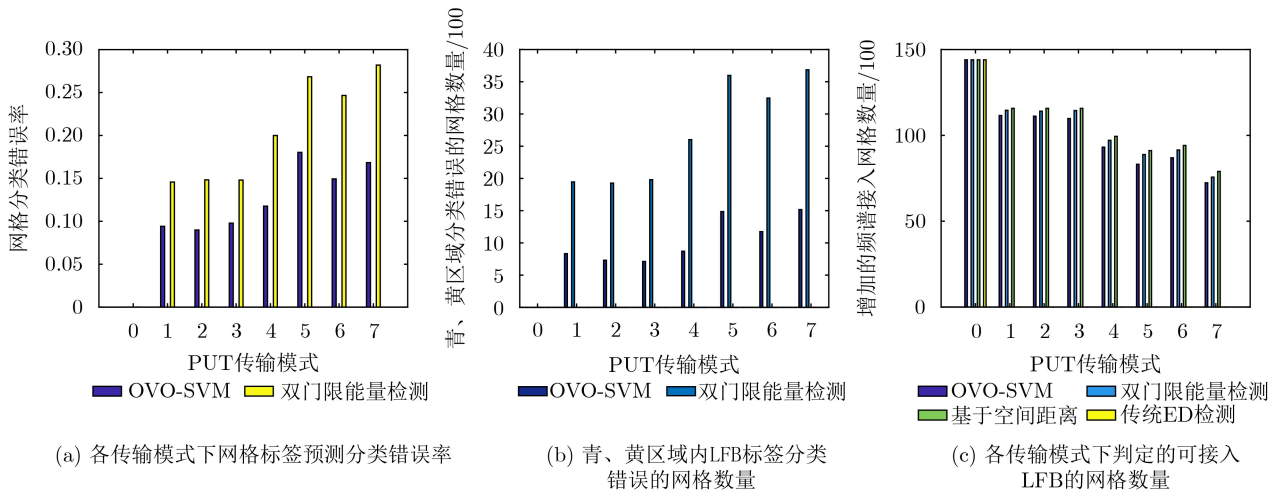


图4 PUT传输功率为43 dBm时，网格分类性能

亦能发现潜在的LFB接入机会，从而极大地增加了LFB的利用效率。

## 6 结论

为了提高蜂窝认知无线网络接入授权频谱的利用率，本文提出了一种基于机器学习经典算法的频谱感知方案。在PUT传输模式分类中，CNN算法具备相同实现条件下的最优的分类准确率；而在面向网格的LFB接入标签预测中，距离计算方法与OVO-SVM具有优于双门限检测算法的性能。仿真实验验证了在与PUT数目、地理位置以及数据充分性等方面相关的不同实现条件下，所提出的频谱感知方案均能达到较好的性能，尽可能减少对PU所产生的干扰，有效地提高SUE在授权频谱中的接入机会，提高了授权频谱利用率。

## 参考文献

- [1] ALI A and HAMOUDA W. Advances on spectrum sensing for cognitive radio networks: Theory and applications[J]. *IEEE Communications Surveys & Tutorials*, 2017, 19(2): 1277–1304. doi: [10.1109/COMST.2016.2631080](https://doi.org/10.1109/COMST.2016.2631080).
- [2] AXELL E, LEUS G, LARSSON E G, et al. Spectrum sensing for cognitive radio: State-of-the-art and recent advances[J]. *IEEE Signal Processing Magazine*, 2012, 29(3): 101–116. doi: [10.1109/msp.2012.2183771](https://doi.org/10.1109/msp.2012.2183771).
- [3] 黄河, 袁超伟. 基于动态自适应双门限能量检测的序贯协作频谱感知算法[J]. *电子与信息学报*, 2018, 40(5): 1037–1043. doi: [10.11999/JEIT170731](https://doi.org/10.11999/JEIT170731).  
HUANG He and YUAN Chaowei. A sequential cooperative spectrum sensing algorithm based on dynamic adaptive double-threshold energy detection[J]. *Journal of Electronics & Information Technology*, 2018, 40(5): 1037–1043. doi: [10.11999/JEIT170731](https://doi.org/10.11999/JEIT170731).
- [4] KIM J and CHOI J P. Sensing coverage-based cooperative spectrum detection in cognitive radio networks[J]. *IEEE Sensors Journal*, 2019, 19(13): 5325–5332. doi: [10.1109/JSEN.2019.2903408](https://doi.org/10.1109/JSEN.2019.2903408).
- [5] 申滨, 王志强, 青晗. 基于次用户功率控制辅助的合作频谱感知[J]. *电子与信息学报*, 2018, 40(10): 2337–2344. doi: [10.11999/JEIT171232](https://doi.org/10.11999/JEIT171232).  
SHEN Bin, WANG Zhiqiang, and QING Han. Secondary user power control aided cooperative spectrum sensing[J]. *Journal of Electronics & Information Technology*, 2018, 40(10): 2337–2344. doi: [10.11999/JEIT171232](https://doi.org/10.11999/JEIT171232).
- [6] MAUWA H, BAGULA A, ZENARO M, et al. Systematic analysis of geo-location and spectrum sensing as access methods to TV white space[J]. *Journal of ICT Standardization*, 2016, 4(2): 147–176. doi: [10.13052/jicts2245-800X.423](https://doi.org/10.13052/jicts2245-800X.423).
- [7] 陈思吉, 王欣, 申滨. 一种基于支持向量机的认知无线电频谱感知方案[J]. *重庆邮电大学学报: 自然科学版*, 2019, 31(3): 313–322. doi: [10.3979/j.issn.1673-825X.2019.03.005](https://doi.org/10.3979/j.issn.1673-825X.2019.03.005).  
CHEN Siji, WANG Xin, and SHEN Bin. A support vector machine based spectrum sensing for cognitive radios[J]. *Journal of Chongqing University of Posts and Telecommunications: Natural Science Edition*, 2019, 31(3): 313–322. doi: [10.3979/j.issn.1673-825X.2019.03.005](https://doi.org/10.3979/j.issn.1673-825X.2019.03.005).
- [8] 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. doi: [10.1109/jsac.2013.131120](https://doi.org/10.1109/jsac.2013.131120).
- [9] AWE O P and LAMBOTHARAN S. Cooperative spectrum sensing in cognitive radio networks using multi-class support vector machine algorithms[C]. *The 9th International Conference on Signal Processing and Communication Systems*, Cairns, Australia, 2015: 1–7. doi: [10.1109/ICSPCS.2015.7391780](https://doi.org/10.1109/ICSPCS.2015.7391780).

- [10] 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. doi: [10.1049/iet-com.2018.5245](https://doi.org/10.1049/iet-com.2018.5245).
- [11] LU Yingqi, ZHU Pai, WANG Donglin, *et al.* Machine learning techniques with probability vector for cooperative spectrum sensing in cognitive radio networks[C]. s2016 IEEE Wireless Communications and Networking Conference, Doha, Qatar, 2016: 1–6. doi: [10.1109/WCNC.2016.7564840](https://doi.org/10.1109/WCNC.2016.7564840).
- [12] CHEN Siji, SHEN Bin, WANG Xin, *et al.* A strong machine learning classifier and decision stumps based hybrid adaboost classification algorithm for cognitive radios[J]. *Sensors*, 2019, 19(23): 5077. doi: [10.3390/s19235077](https://doi.org/10.3390/s19235077).
- [13] WEI Zhiqing, FENG Zhiyong, ZHANG Qixun, *et al.* Three regions for space-time spectrum sensing and access in cognitive radio networks[C]. 2012 IEEE Global Communications Conference, Anaheim, USA, 2012: 1283–1288. doi: [10.1109/GLOCOM.2012.6503290](https://doi.org/10.1109/GLOCOM.2012.6503290).
- [14] 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. doi: [10.3969/j.issn.1001-506X.2016.05.27](https://doi.org/10.3969/j.issn.1001-506X.2016.05.27).  
RUAN Lihau, LI Yong, and CHENG Wei. Novel region division approach for joint space-time spectrum 2-dimensions sensing in cognitive radio[J]. *Systems Engineering and Electronics*, 2016, 38(5): 1146–1152. doi: [10.3969/j.issn.1001-506X.2016.05.27](https://doi.org/10.3969/j.issn.1001-506X.2016.05.27).
- [15] SINGH G and CHHABRA I. Effective and fast face recognition system using complementary OC-LBP and HOG feature descriptors with SVM classifier[J]. *Journal of Information Technology Research*, 2018, 11(1): 91–110. doi: [10.4018/JITR.2018010106](https://doi.org/10.4018/JITR.2018010106).
- [16] DADI H S, PILLUTLA G K M, and MAKKENA M L. Face recognition and human tracking using GMM, HOG and SVM in surveillance videos[J]. *Annals of Data Science*, 2018, 5(2): 157–179. doi: [10.1007/s40745-017-0123-2](https://doi.org/10.1007/s40745-017-0123-2).
- [17] 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. doi: [10.1109/JSTSP.2018.2796446](https://doi.org/10.1109/JSTSP.2018.2796446).
- 申 滨: 男, 1978年生, 教授, 研究方向为大规模MIMO系统、认知无线电等.
- 王 欣: 女, 1992年生, 硕士生, 研究方向为认知无线电.
- 陈思吉: 男, 1993年生, 硕士生, 研究方向为认知无线电.
- 崔太平: 男, 1981年生, 讲师, 研究方向为认知无线电、车联网等.

责任编辑: 余 蓉