

文章编号: 2095-4980(2022)12-1343-07

数据驱动的开放动态频谱接入系统构建方法

麦伟民, 彭福州, 谭超镭, 周拱朗, 陈翔

(中山大学 电子与信息工程学院, 广东 广州 510006)

摘要: 在认知无线电(CR)背景下, 动态频谱接入已成为提高无线网络频谱利用率的重要途径。基于全球移动通信系统-铁路(GSM-R)系统中采集的细粒度频谱监测数据, 提出一种数据驱动的深度学习方法, 建模频谱模式, 并建立一套动态频谱接入访问框架。采用一种深度频谱生成模型指导频谱分配; 设计一种综合递归序列表征与场景特征嵌入的深度网络, 建模和预测短时频谱占用情况, 并由此提出一种动态信道接入策略。进一步, 利用软件无线电(SDR)平台实现一套跳频系统, 并将其与动态频谱接入策略进行集成。使用真实的历史频谱数据评估该系统的数据吞吐能力, 测试结果表明, 所提方法及构建的跳频系统能有效提高机会通信能力, 高效利用频谱资源。该频谱接入框架及SDR系统实现具有较强的通用性, 易于集成到不同场景和频段的系统中。

关键词: 认知无线电; 动态频谱接入; 频谱占用预测; 跳频系统; 软件无线电

中图分类号: TN929.5

文献标志码: A

doi: 10.11805/TKYDA2022030

A data-driven method for open dynamic spectrum access system

MAI Weimin, PENG Fuzhou, TAN Chaolei, ZHOU Gonglang, CHEN Xiang

(School of Electronics and Information Technology, Sun Yat-sen University, Guangzhou Guangdong 510006, China)

Abstract: In the context of Cognitive Radio(CR), dynamic spectrum access has become a key approach to improve the spectrum utilization in wireless network. In this paper, using fine-grained spectrum measurement data collected from Global System for Mobile Communications-Railway(GSM-R), a data-driven deep-learning method is proposed to model the spectrum pattern and a framework is developed for dynamic spectrum access. A deep spectrum generative model is adopted to guide the spectrum allocation. A deep network that combines recurrent series model and background feature embeddings is developed to model and predict the short-term spectrum occupancy, then a strategy is proposed for dynamic channel access. Furthermore, a frequency-hopping system is implemented with Software Defined Radio(SDR) platform and it is integrated with the proposed strategy. The throughput capacity of this system is evaluated with real-world historical spectrum data. It is shown that the proposed method and system can enhance the ability of opportunistic communication and utilize the spectrum resource efficiently. The proposed spectrum access framework and the implementation with SDR are of great generality, so that they can be easily integrated into systems with different scenarios and frequency spans.

Keywords: Cognitive Radio; dynamic spectrum access; spectrum occupancy prediction; frequency hopping system; Software Defined Radio

随着无线业务的快速增长, 对频谱资源的需求激增。现有的传统的静态频谱分配方式由政府或相关管理组织将某一段频谱固定授权给特定系统或用户, 这种分配方式无疑加剧了频谱资源的紧张。根据美国联邦通信委员会的统计调研显示, 有相当数量的授权频谱资源的利用率仅在15%~85%之间, 即在实际应用中, 一些频段大部分时间并没有被占用^[1]。这种静态频谱分配方式使得未获授权的用户不能利用授权频段, 限制了频谱的使用效率, 也难以满足未来的通信需求。

为提高频谱利用率, 认知无线电(CR)技术自提出后受到广泛关注。认知无线电技术的核心思想是: 在不对授

收稿日期: 2021-10-25; 修回日期: 2021-12-13

基金项目: 国家重点研发计划资助项目(2019YFE0114000)

权用户产生干扰的情况下,未授权用户可以侦测“频谱空穴”,利用空闲的授权频段进行机会性接入通信。其研究涉及频谱感知、发射功率控制、动态频谱接入等多个方向,其中探索真正智能化的动态频谱接入成为构建系统很关键的一个环节^[2]。学界对于动态频谱接入系统架构及各细分领域的算法方案有较多成果积累,但现阶段仍难以见到较成熟的应用系统部署落地。这一方面是由于智能动态接入算法的复杂性,使系统开发实现较困难,模型方法在不同通信场景下适用性不高;另一方面,专用通信设备的灵活性与拓展性相对较低,系统间的兼容部署及升级维护成本较高。因此,对模型方法通用易实现、便于通信系统间兼容部署及场景拓展的CR动态频谱接入系统的研究十分必要。

为研制开放性高、灵活性强的系统,学界更加关注软件无线电(SDR)技术^[3],使用软件定义的无线通信协议在通用平台上实现无线系统。SDR系统的工作频段、数据格式等可通过软件配置更新,为系统部署与拓展开放带来了便利。采用软件通用化的方式研制CR动态频谱接入系统,易于在未来与诸多的无线系统平台集成,促进通信系统间的开放协同,真正推动CR系统的落地频谱资源开放共享。

随着数据挖掘技术的发展,许多深度数据模型日渐成熟,数据驱动的方法为研究开放CR机会通信系统的频谱分配与机会接入带来了新思路。各类通信场景下的频谱监测系统在长期运作中积累了大量的扫频历史数据,从频谱监测大数据中感知真实物理情境下已有授权用户的工作占用模式以及环境干扰噪声的影响,可支撑智能化算法策略构建,也可使方法模型在不同通信系统场景下的通用性更强。

综上,用数据驱动的方式,结合软件无线电的系统构建,探讨模型智能化、场景通用性强、易推广部署的开放CR频谱动态接入系统具有重要的战略意义。基于该背景,本文提出一种数据驱动的开放动态频谱接入系统的构建方法。基于铁路GSM-R系统的细粒度真实频谱测量数据,阐述了动态频谱接入系统下大时间尺度频谱分配与小时间尺度机会接入的架构。采用深度递归网络结合时空信息嵌入表征与残差网络,对频谱占用模式进行预测,并采用概率跳频方式进行机会接入,在通用SDR平台上实现了一套跳频系统,并将其与动态频谱接入策略集成进行验证。实验表明,所提方法及系统可有效提高机会通信的吞吐量,系统实现具有较强通用性,在未来易与不同场景的无线系统集成。

1 相关工作

目前,频谱预测与动态接入方法得到广泛研究。传统方法采用支持时间序列模型、支持向量机(Support Vector Machine, SVM)、贝叶斯估计等回归预测技术对频谱进行预测建模^[4]。信道可用性状态变化往往能表示成有限状态马尔科夫过程,在信道状态观测感知模糊的问题场景下,隐马尔科夫模型(Hidden Markov Model, HMM)得到了特别关注。Nguyeny T等^[5]直接使用HMM估计信道状态模型参数,进行预测指导接入。为提高预测的准确性,HMM模型也可通过硬融合^[6]与软融合^[7]的方式拓展至多观测协同频谱占用情况预测。Mosavat-Jahromi H等^[8]采用自回归滑动平均模型和低通滤波相结合建立信道模型。深度学习技术的发展为相关研究提供了新的方法模型,在信道状态部分可观测的马尔科夫过程视角下,WANG S等^[9]与YAN Z等^[10]利用深度强化学习方法,将信道状态估计与动态接入决策结合。SONG H等^[11]和ALBINSALD H等^[12]对强化学习在动态频谱接入的领域有进一步的探讨。在功率控制方面,XIAO L等^[13]研究了大规模协同认知无线网络中二次用户的抗干扰功率控制问题。Rutagemwa H等^[14]从数据驱动的方法出发,使用多时间尺度的深度序列生成模型预测生成的未来预估频谱,进而指导认知无线电中的频谱分配。Kaur A在综述^[15]中对近几年的动态频谱接入的机器学习方法进行了总结。

本文从数据驱动的视角,提出一种简洁通用的开放动态频谱接入系统的构建方法。在大时间尺度下的频谱分配后,设计一种综合深度递归序列表征与时段等嵌入表征的深度网络模型,建模和预测短时频谱占用情况,进而采用概率跳频进行动态信道接入。

2 GSM-R系统及频谱监测数据

GSM-R系统是为铁路及其应用服务的通信系统,其上行频段为885~889 MHz,下行频段为930~934 MHz,相邻频道间隔为200 kHz。为保障系统正常运行,各站点装有固定的频谱监测扫频系统对相应频段范围内的频谱状况进行监测。频谱扫频数据记录中包括上述频段内各频点细粒度的电平/功率数据,频点间隔约为9.5 kHz,扫描时间粒度可达秒级,具有较高的时间与频率分辨率。

某著名站点一天内的上行频谱情况如图1所示。可以看到,在时间方向上呈现离散条带式的亮斑,这是列车或铁路系统其他应用通信时,该频段范围内的各个信道被间歇性地占用。各信道显示出不同的占用模式,且底噪干扰也有区别,凌晨时段频谱由于铁路检修停运无通信而呈现深色低电平功率。

从图 1 可见，在典型的授权频段模式下，频谱利用率并不高。若能够动态分配系统内用频台站使用频段，允许其他用频台站或设备利用频谱空穴在其中进行机会性动态频谱接入，可有效提高频谱利用率，同时提升通信设备容量及效率。

本文拟基于该 GSM-R 频谱监测数据，采用数据驱动的建模方法，对频谱模式进行建模预测，并基于通用 SDR 平台，搭建一套动态频谱接入验证系统。

3 开放动态频谱访问系统构建方法

3.1 频谱动态分配与接入整体框架

GSM-R 场景下，一个可能的认知无线电动态频谱的动态分配与接入系统架构如图 2 所示。监测与调度中心维护一个大型的频谱监测数据库，定期汇总各站点频谱监测数据。监测调度中心含频谱分配控制单元(图 2 左虚线部分)，负责学习频谱的长期概率分布，在大时间尺度下向系统内用频台站(图 2 右虚线部分)或外部申请接入的设备动态分配频段。用频台站/设备则在分配的若干频道上进行频道占用度智能感知后，通过选频及概率跳频的方式实现高效的机会接入。




Fig.1 Dynamic thermodynamic diagram of uplink frequency-power on one railway station

图 1 某站点单日上行频带功率时变热力图

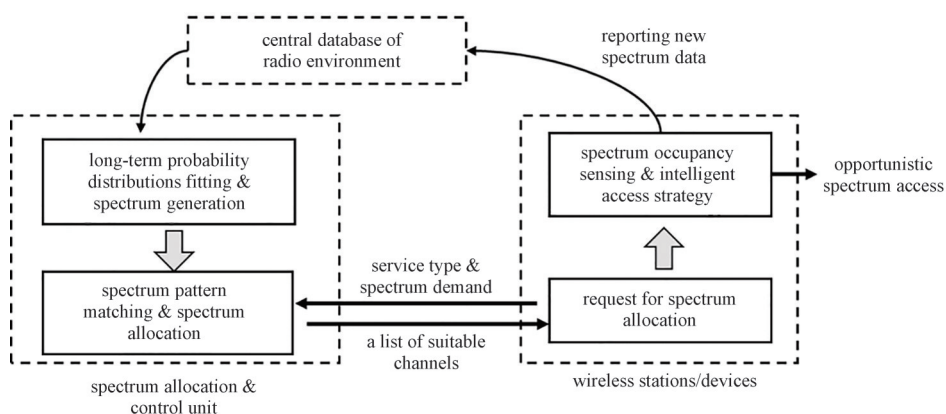


Fig. 2 Dynamic spectrum allocation and access framework

图 2 频谱动态分配与接入整体架构

3.2 动态频谱分配

系统频段下可用信道数量较多，当全局频谱分配控制单元对全局长线频谱数据进行汇总时，便能建模频谱环境的长期变化态势，为用频台站动态分配若干频道资源。在宏观频谱分配环节中，本系统将长短期记忆(Long Short-Term Memory, LSTM)网络模型微调，使其适配于频谱功率数据的输入输出，用以学习 GSM-R 频谱的长期概率分布，并采样生成未来大时间尺度下的频谱。同时借鉴文献[14]中的频谱分配方法，在垂直频谱共享情形下，将上述模型生成的未来预估频谱与用户/台站对应业务类型的预估频谱进行模拟匹配共享，采用最小化最大累积等待退避时间的准则分配准入的频谱信道。

3.3 频谱占用预测与动态机会接入方法

频谱生成模型所合成的未来频谱，在大时间尺度下与真实频谱进行概率分布假设检验时，认为一致，可用于指导宏观的频谱动态分配，但不意味它在短时频谱预测中效果显著。对于寻求机会通信的用频设备，往往频谱感知能力更弱，且没有监测中心大规模的长期频谱数据库，因此设备在短时频谱感知下如何利用数据驱动的深度模型智能地机会接入成为本系统的设计核心。

假设设备在单位时间只能感知单一信道，且遵循先听后发(listen-before-talk)的原则，即当某时隙中监听到所选择的信道被占用时，为避免碰撞将进行退避。直观上看，为提高接入的成功率及吞吐量，一个次级用户(Secondary User, SU)应该选择发生碰撞少的信道进行机会接入。由于频谱时变仅短时平稳，用短时间内的信道

占用度刻画信道的可用程度更容易预测其模式，指导机会接入更有实用意义。

对频谱监测数据统计各信道单位时间间隔(约 1min)内的占用度，将频谱数据表示成信道占用度的时间序列 $\{x_1, x_2, \dots, x_t, \dots\}$ ，第 t 个单位时间间隔内的频道占用度向量 $\mathbf{x}_t = [x_{t1}, x_{t2}, \dots, x_{tN}]^T$ ，其中各元素分别表示对应时间获分配的 N 个信道的占用度。记用频设备/用户可观测的历史频谱长度为 τ ，则其在时间 t 可得历史频谱占用度观测序列 $\{x_{t-\tau+1}, \dots, x_{t-1}, x_t\}$ 。其他额外特征如时段特征、站点环境特征等记作 $\{u_1, u_2, \dots, u_m\}$ ， m 为额外特征数量。则短时频谱占用度预测可形式化地表述为：

$$\hat{\mathbf{x}}_{t+1} = f(\mathbf{x}_{t-\tau+1}, \dots, \mathbf{x}_{t-1}, \mathbf{x}_t, u_1, \dots, u_m) \quad (1)$$

式中： $\hat{\mathbf{x}}_{t+1}$ 为下一个时间单位的频谱占用度 \mathbf{x}_{t+1} 的估计值； $f(\cdot)$ 即需构建的数据驱动深度预测模型。

本文设计了如图 3 所示的短时频谱信道占用度预测模型框架。通过深度递归网络(如门控循环单元 GRU^[16]与 LSTM^[17])提取频谱占用度序列的时变模式信息，同时将频谱相关的非序列特征输入一个嵌入层进行嵌入表征，两部分的输出共同输入到后级的多层神经回归网络中对未来的占用度进行预测。

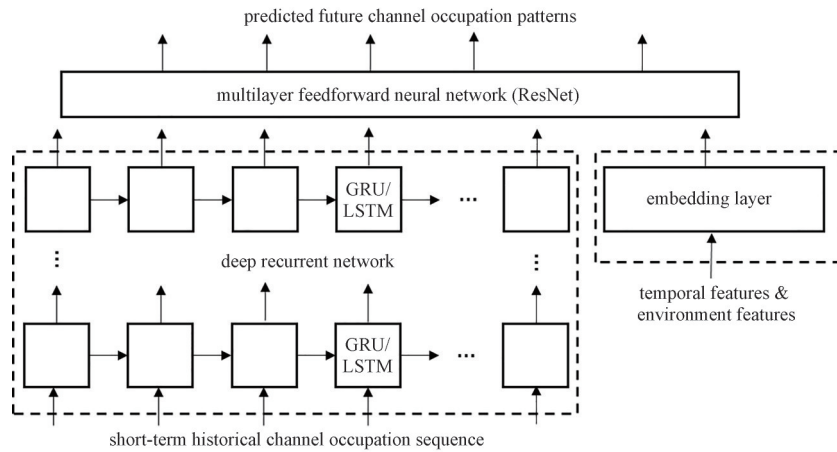


Fig.3 Prediction framework of spectrum channel occupation
图3 频谱信道占用度预测框架

GRU 与 LSTM 为特殊的递归序列模型，通过在递归单元中增加门控结构控制信息的更新传递，使模型能更好地建模序列的长线依赖与变化特性。以 GRU 模型为例，输入的频谱占用度观测序列 $\{x_{t-\tau+1}, \dots, x_{t-1}, x_t\}$ 的每一个时间步依次进行下列迭代：

$$\mathbf{r}_t = \sigma(\mathbf{W}_r [\mathbf{h}_{t-1}, \mathbf{x}_t]) \quad (2)$$

$$\mathbf{z}_t = \sigma(\mathbf{W}_z [\mathbf{h}_{t-1}, \mathbf{x}_t]) \quad (3)$$

$$\tilde{\mathbf{h}}_t = \tanh[\mathbf{W}_h (\mathbf{r}_t * \mathbf{h}_{t-1}, \mathbf{x}_t)] \quad (4)$$

$$\mathbf{h}_t = (1 - \mathbf{z}_t) * \mathbf{h}_{t-1} + \mathbf{z}_t * \tilde{\mathbf{h}}_t \quad (5)$$

式中： \mathbf{r}_t 和 \mathbf{z}_t 分别表示重置门与更新门； \mathbf{h} 为对应时间步的隐藏向量； $\sigma(\cdot)$ 表示 sigmoid 函数； $\mathbf{W}_r, \mathbf{W}_z, \mathbf{W}_h$ 为待训练参数。深度递归网络每一时间步的输入占用度向量包含各个频谱信道的情况，从而隐式地挖掘了信道间的联系。

额外的非序列特征则通过一个嵌入层 Emb(\cdot) 得到其密集表征向量：

$$\tilde{\mathbf{u}}_i = \text{Emb}(u_i) \quad (6)$$

将时段特征、站点特征输入嵌入层，其他频谱相关特征如环境参数、电波态势参数等也可以作为额外的特征，得到各时间步隐藏向量表征与额外特征的嵌入表征后，将它们拼接后输入至多层回归网络的输出层，如式(7)所示。系统中采用带有层间残差连接的 ResNet 网络^[18]，可以很容易地拟合恒等映射，使网络加深后还能保持稳定的性能。

$$\hat{\mathbf{x}}_{t+1} = \text{ResNet}(\text{Concat}(\mathbf{h}_{t-\tau+1}, \dots, \mathbf{h}_t, \tilde{\mathbf{u}}_1, \dots, \tilde{\mathbf{u}}_m)) \quad (7)$$

通过极小化估计均方误差训练该频谱占用度预测模型。

通过组合深度网络结构得到各信道短时占用度预测结果后，通过概率选频/跳频的方式进行机会接入，如图 4

所示。根据各信道的占用度情况，择优选择小于对应设定阈值的若干信道作为机会接入的备选信道，随后通过变换矩阵 W 及 softmax 操作，将备选信道的占用度映射为各信道在后续跳频通信时被选择的概率。次级用户依照该概率在各个信道上进行随机跳频通信，如图 5 所示。


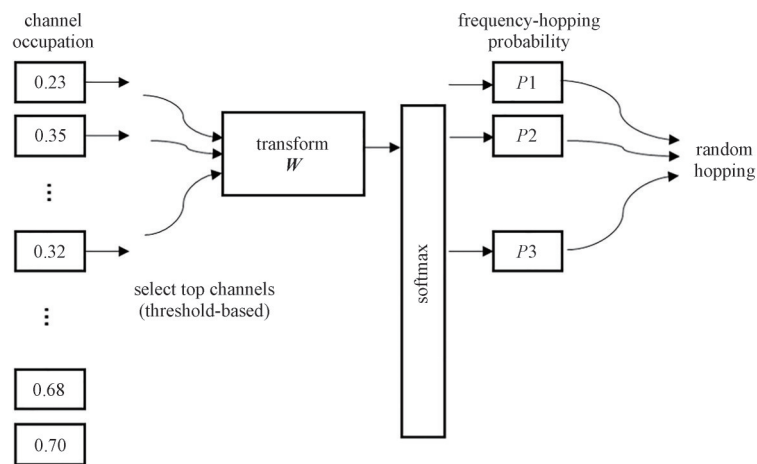


Fig.5 Random frequency-hopping pattern selection strategy
图 5 随机跳频图案选择策略

Fig.4 Access channel selection and random frequency-hopping strategy
图 4 接入信道选择及随机跳频策略

本文采用基于信道占用度预测选频后再随机跳频的方法是因为频谱占用度带来模型预测增益的同时，也会使短时段内信道真实频谱模糊化。实际通信系统通过跳频的方式在多个良好的信道上进行跳频接入，可使系统吞吐量更加稳定，也便于在未来拓展至较大规模用户的机会接入系统。

4 系统搭建与实验分析

在 NI 的通用 SDR 平台上实现跳频动态频谱访问架构的演示系统，并将其与所提出的频谱占用预测与机会接入策略相集成。发射机的结构如图 6 所示，接收机的结构与其反面对称。值得一提的是，该系统可以灵活调整中心频点、频带宽度和跳频间隔，以满足不同通信场景的需求，从而能够与不同的 SDR 系统实现相兼容。演示系统实物图如图 7 所示，上位机电脑中存储频谱数据库，同时控制软件无线电 (Universal Software Radio Peripheral, USRP) 平台收发信机，大屏显示实时频谱资源瀑布图以及系统跳频情况。

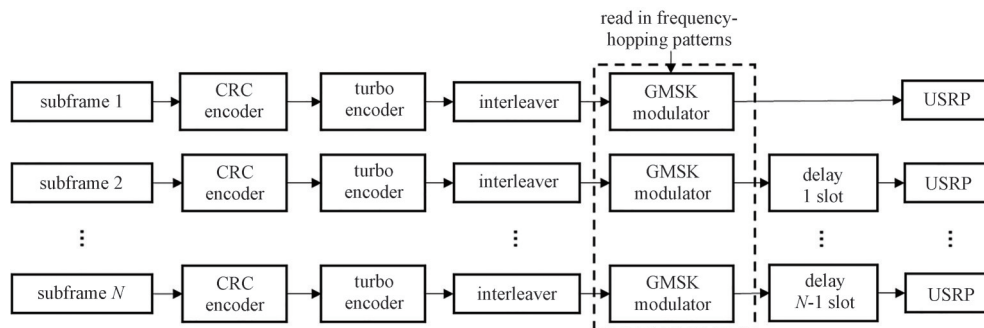


Fig.6 Transmitter structure of frequency-hopping system
图 6 跳频系统发信机结构

实际操作中，参考 GSM-R 空口实际使用经验性参数，频谱占用预测模型中设定深度递归网络输入约 15 min 的频谱数据，层数为 2，隐层维度 256。递归序列的其他参数由网格搜索调优得到，实际操作中时段等特征嵌入维度为 20；输出层 ResNet 层数为 3，隐层维度 128。

5 实验结果

使用真实的 GSM-R 系统频谱历史数据训练并评估该系统的吞吐量性能，为反映本文所提方法相比于传统跳频方案的增益以及与实际信道接入选择的接近程度，本文借鉴文献[19]中的基线对比方式。如图 8 所示，设定一

个时隙可发送一个数据包，横轴代表时隙数，纵轴代表成功发送数据包数量。吞吐量性能的差别源于当用频台站/设备进行动态机会接入时，若某一个时隙选择了被占用的频谱信道或强干扰的信道，为避免碰撞则会退避，因而降低单位时间内的数据包吞吐。实测吞吐量曲线结果表明，本文方案的吞吐量优于其他两种基线方法，相同时间下整体累计吞吐量更高，更接近于理想情况下的吞吐量曲线。两种基线方法的吞吐量增长呈现较明显的阶梯折线状，这是由于较极端的信道选择导致信道条件好时吞吐量迅速提高，而拟接入的信道高占用或强干扰时基本无数据传输。本文方法相比于这两种基线方法，累积吞吐量增加更加平稳，这有利于保持系统通信质量的稳定。实验表明，所提方法和构建的系统能够提高机会通信能力，智能地捕捉不同时隙中的“频谱空穴”进行动态频谱接入，有效地利用频谱资源。




Fig.7 Prototype of demonstration
图7 演示系统实物图

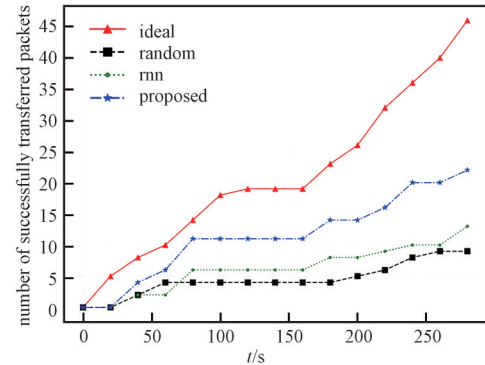


Fig.8 Throughput curves of system
图8 系统吞吐量曲线

6 结论

本文基于 GSM-R 系统的真实频谱测量数据，提出了一种数据驱动深度频谱模式学习方法，并构建了一套动态频谱接入系统。所提方法及构建的系统具有通用性，容易推广至其他频段与带宽下的通信系统中，对未来开放频谱接入系统的构建具有重要意义。未来，还将基于本文方法进行拓展，探讨多用户共同寻求机会通信场景下更优的动态频谱接入系统。

参考文献：

- [1] Federal Communications Commission. Notice of proposed rule making and order[R]. ET Docket No. 03-322. 2003.
- [2] AKYILDIZ I F, LEE W Y, VURAN M C, et al. Next generation/dynamic spectrum access/cognitive radio wireless networks: a survey[J]. Computer Networks, 2006, 50(13): 2127-2159.
- [3] MITOLA J. Software radios: survey, critical evaluation and future directions[J]. IEEE Aerospace and Electronic Systems Magazine, 1993, 8(4): 25-36.
- [4] BKASSINY M, LI Y, JAYAWEERA S K. A survey on machine-learning techniques in cognitive radios[J]. IEEE Communications Surveys & Tutorials, 2012, 15(3): 1136-1159.
- [5] NGUYEN T, MARK B L, EPHRAIM Y. Hidden Markov process based dynamic spectrum access for cognitive radio[C]// 2011 45th Annual Conference on Information Sciences and Systems. Baltimore, MD, USA: IEEE, 2011: 1-6.
- [6] ELTOM H, KANDEEPAN S, LIANG Y C, et al. HMM based cooperative spectrum occupancy prediction using hard fusion[C]// 2016 IEEE International Conference on Communications Workshops (ICC). Kuala Lumpur, Malaysia: IEEE, 2016: 669-675.
- [7] ELTOM H, KANDEEPAN S, LIANG Y C, et al. Cooperative soft fusion for HMM-based spectrum occupancy prediction[J]. IEEE Communications Letters, 2018, 22(10): 2144-2147.
- [8] MOSAVAT-JAHROMI H, LI Y, CAI L, et al. Prediction and modeling of spectrum occupancy for dynamic spectrum access systems[J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(3): 715-728.
- [9] WANG S, LIU H, GOMES P H, et al. Deep reinforcement learning for dynamic multichannel access in wireless networks[J]. IEEE Transactions on Cognitive Communications and Networking, 2018, 4(2): 257-265.
- [10] YAN Z, CHENG P, CHEN Z, et al. Gaussian process reinforcement learning for fast opportunistic spectrum access[C]// 2019 IEEE Global Communications Conference (GLOBECOM). Waikoloa, HI, USA: IEEE, 2019: 1-6.
- [11] SONG H, LIU L, ASHDOWN J, et al. A deep reinforcement learning framework for spectrum management in dynamic spectrum access[J]. IEEE Internet of Things Journal, 2021, 8(14): 11208-11218.

- [12] ALBINSAID H,SINGH K,BISWAS S,et al. Multi-agent reinforcement learning based distributed dynamic spectrum access[J]. IEEE Transactions on Cognitive Communications and Networking, 2022,8(2):1174-1185.
- [13] XIAO L,LI Y,LIU J,et al. Power control with reinforcement learning in cooperative cognitive radio networks against jamming[J]. Journal of Supercomputing, 2015(71):3237-3257.
- [14] RUTAGEMWA H,GHASEMI A,LIU S. Dynamic spectrum assignment for land mobile radio with deep recurrent neural networks[C]// 2018 IEEE International Conference on Communications Workshops(ICC Workshops). Kansas City,MO,USA:IEEE, 2018:1-6.
- [15] KAUR A,KUMAR K. A comprehensive survey on machine learning approaches for dynamic spectrum access in cognitive radio networks[J]. Journal of Experimental & Theoretical Artificial Intelligence, 2022,34(1):1-40.
- [16] CHO K, VAN-MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]// Conference on Empirical Methods in Natural Language Processing(EMNLP 2014). Doha, Qatar:ACL, 2014:1724-1734.
- [17] HOCHREITER S,SCHMIDHUBER J. Long Short-Term Memory[J]. Neural Computation, 1997,9(8):1735-1780.
- [18] HE K,ZHANG X,REN S,et al. Deep residual learning for image recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas,NV,USA:IEEE, 2016:770-778.
- [19] 叶芝慧,冯奇,王健. 基于学习策略的动态频谱接入信道选择及系统性能[J]. 东南大学学报(自然科学版), 2012,42(6):1041-1046. (YE Zhihui,FENG Qi,WANG Jian. Learning-based channel selection and system performance of dynamic spectrum access[J]. Journal of Southeast University(Natural Science Edition), 2012,42(6):1041-1046.)

作者简介：

麦伟民(1997-), 男, 在读硕士研究生, 主要研究方向为电信大数据、交通大数据.email: maiwm3@mail2.sysu.edu.cn.

彭福洲(1997-), 男, 在读硕士研究生, 主要研究方向为无线通信、软件无线电.

谭超镛(1998-), 男, 在读硕士研究生, 主要研究方向为深度学习、计算机视觉.

周拱朗(1998-), 男, 在读硕士研究生, 主要研究方向为人工智能、硬件加速.

陈翔(1980-), 男, 博士, 副教授, 主要研究方向为无线通信、移动通信、电信大数据.