



研究与开发

基于 CBR 与合作 Q 学习的分布式 CRN 资源分配算法

徐琳, 赵知劲

(杭州电子科技大学通信工程学院, 浙江 杭州 310018)

摘要: 针对分布式认知无线网络的信道和功率分配问题, 提出一种基于案例推理与合作的 Q 学习算法。为了优化 Q 学习算法的 Q 初始化, 将当前问题和历史案例依据相似度函数进行匹配, 提取匹配案例的 Q 值并在归一化后作为初始值, 进行合作 Q 学习。合作 Q 学习是基于总奖赏值进行的, 各 Agent 以不同权值融合其他具有更高奖赏值的 Agent 的 Q 值来获取学习经验, 以减少不必要的探索。仿真结果表明, 该算法提高了认知系统信道和功率分配的能量效率, 加快了系统的收敛速度。

关键词: 认知无线电; 合作 Q 学习; 案例推理; 信道和功率分配; 能量效率; 收敛速度

中图分类号: TP925

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2019005

A distributed CRN resource allocation algorithm based on CBR and cooperative Q-learning

XU Lin, ZHAO Zhijin

School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

Abstract: In order to solve the problem of channel and power allocation in distributed cognitive radio networks (CRN), a case-based reasoning (CBR) and cooperative Q-learning algorithm was proposed. In order to optimize the Q initialization of Q-learning algorithm, the current problem and the historical case were matched according to the similarity function, the Q value of the matching case was extracted and normalized as the initial value. Cooperative Q-learning was based on the total reward value, and each agent integrates the Q values of other agents with higher reward values with different weights to gain learning experience to reduce unnecessary exploration. Simulations show that the proposed algorithm can improve the energy efficiency of the cognitive system's channel and power allocation, and accelerate the convergence speed of the system.

Key words: cognitive radio, cooperative Q-learning, case-based reasoning, channel and power allocation, energy efficiency, convergence speed

收稿日期: 2018-05-17; 修回日期: 2018-11-30

基金项目: “十二五”国防预研项目 (No.41001010401)

Foundation Item: The National Defense Pre-Research Project During the Twelfth Five-year Plan Period (No.41001010401)



1 引言

物理频谱的有效利用是无线通信中的一个基本问题。针对传统频谱管理方案存在的频谱利用率低的问题,提出了一种认知无线电技术^[1]。认知无线电允许认知用户在不干扰主用户通信的前提下,动态地接入空闲信道,从而有效地提高频谱利用率^[2]。动态资源分配的一种认知无线电关键技术是通过信道、功率和调制方式等传输参数的优化来提高系统性能。

强化学习通过奖惩原则来优化决策,是一种人工智能算法^[3]。Q 学习 (Q-learning) 是一种使用最广泛的强化学习算法,已经成功应用于认知无线网络 (cognitive radio network, CRN) 的动态资源分配。参考文献[4]提出多 AgentQ 学习协作算法,Agent 根据自身的变化周期地进行合作和调整参数,提高了收敛速度,但该算法只考虑信道分配。参考文献[5]利用经典独立 Q 学习 (independent Q-learning, IQL) 实现信道和功率分配,但收敛速度较慢。参考文献[6]提出的基于 WoLF (win-or-learn-fast) Q 学习算法,加快了收敛速度,但系统能量效率较低。针对以上问题,首先提出了一种基于总奖赏值的合作 Q 学习算法,各 Agent 利用其他具有更大奖赏值 Agent Q 值,促进自身学习,在提高能量效率的同时加快了算法收敛速度。但此算法在 Q 学习初期,通常将 Q 值初始化为 0,影响了算法的寻优效率。案例推理 (case-based reasoning, CBR) 是一种人工智能技术,利用存储案例来指导新问题的解决^[7]。参考文献[8]将案例推理与粒子群算法结合应用于认知无线电 NC-OFDM 的资源分配,明显缩短了收敛时间。为了优化合作 Q 学习算法的 Q 值初始化,提高分布式多认知用户系统的信道和功率联合分配性能,本文提出一种基于案例推理与合作 Q 学习 (case-based reasoning and cooperative Q-learning, CBRCQL) 分配算法。该算法首先在

案例库中进行当前问题的案例匹配,选择相似度最大的匹配案例的 Q 值初始化学习算法,然后进行合作 Q 学习,使得各 Agent 在学习之初就接近最优解,从而进一步提高系统能量效率,加快收敛速度。

2 CBRCQL 算法

2.1 CBRCQL 学习模式

CBRCQL 算法的学习过程如图 1 所示,图 1 中虚线框部分为案例推理算法。




图 1 CBRCQL 算法的学习过程

针对新案例,首先与案例库中案例进行匹配,选择最匹配的案例初始化新案例的 Q 学习,并进行合作 Q 学习。在学习结束后,检验新案例的决策结果是否优于案例库中最差的案例,若是,则更新案例库。

2.2 合作 Q 学习

强化学习算法通过反复的试错实验来建立问题的决策方案^[9],其系统主要包括 Agent 和环境,多 Agent 强化学习是多用户认知网络中动作决策的一种重要方法^[10]。其中,每个 Agent 都是一个独立的学习体,只维护自己的 Q 值表,然后利用更新后的 Q 值来修正动作策略,从而做出最佳决策。

各 Agent 的独立学习可能使环境发生变化,此时,如果 Agent 进行合作学习往往能取得更优的分配策略。因此,本文提出一种基于奖赏值的合作 Q 学习 (cooperative Q-learning, CQL) 算法。

本文中各 Agent 均是同构的,学习目标都是得到使系统性能最大化的最佳分配策略。因而,




图2 合作Q学习算法模型

其学习过程是相似的，各 Agent 间可以通过共享和融合其他获得更大奖赏值的 Agent Q 值进行合作学习，相当于学习其他分配效果更好的 Agent 的经验，减少对不必要动作的尝试，从而提高单个 Agent 的性能以及算法的收敛速度。合作 Q 学习算法的模型如图 2 所示。

合作的前提是考虑系统的整体收益，若当前总奖赏值 $\sum_i r_t^i$ 大于前一次迭代的总奖赏值 $\sum_i r_{t-1}^i$ ，则各 Agent 进行独立学习；若当前总奖赏值 $\sum_i r_t^i$ 小于前一次迭代的总奖赏值 $\sum_i r_{t-1}^i$ ，则 Agent 间进行图 2 中左边部分的合作学习，对于 Agent i ，合作期间的 Q 值计算式如式 (1) 所示：

$$Q_t^i(s,a) = \sum_j \omega_{ij} Q_t^j(s,a), \quad i=1,2,\dots,K \quad (1)$$

其中， ω_{ij} 为折扣权值，计算式如式 (2) 所示：

$$\omega_{ij} = \begin{cases} \delta & , \quad i=j \\ (1-\delta) \frac{r_j - r_i}{\sum_k (r_k - r_i)} & , \quad r_j > r_i, r_k > r_i \\ 0 & , \quad \text{其他} \end{cases} \quad (2)$$

其中， δ 为常数， r_j 为 Agent j 当前时刻的奖赏值。

因此，CQL 算法的流程如下。

(1) 初始化 Q 值，给定 δ 、总迭代次数以及其他学习参数。

重复以下迭代，直到达到总迭代次数。

(2) Agent 根据动作策略选择动作 a 。

(3) 由所选的动作计算奖赏值，若 $\sum_i r_t^i > \sum_i r_{t-1}^i$ ，则各 Agent 进行独立 Q 学习；若 $\sum_i r_t^i < \sum_i r_{t-1}^i$ ，则根据式 (1) 和式 (2) 进行合作学习。

(4) 更新相应参数。

2.3 案例推理

案例推理模型如图 3 所示。




图3 案例推理模型

案例推理就是借鉴以往解决相似问题的经验来处理新案例。首先，提取新案例的特征，其次，由案例匹配方法在案例库找到一个最类似的案例，再次，对其执行方案进行适当修正或直接作为新案例的解决方案，最后，对案例库进行更新^[11]。

设案例库中案例 C_k 的表示如下：

$$C_k: \langle V_k, Q_k, E_k \rangle, \quad k=1,2,\dots,L \quad (3)$$



其中, L 为案例库中的总案例数, Q_k 为案例 k 的解决方案, E_k 为案例 k 的效用值, V_k 为案例 k 存储的特征向量。

特征向量 V_k 可表示为:

$$V_k = (v_{k,1}^1, v_{k,2}^1, \dots, v_{k,m}^1, \dots, \underbrace{v_{k,1}^l, v_{k,2}^l, \dots, v_{k,m}^l}_{\text{第 } l \text{ 个特征的第 } m \text{ 个分量}}, \dots),$$

$$l=1, 2, \dots, n \quad (4)$$

其中, n 表示案例的特征个数。

假设新案例的特征向量为 $X = (x_1^1, x_2^1, \dots, x_m^1, \dots, x_1^l, x_2^l, \dots, x_m^l, \dots)$, 采用欧氏距离作为衡量案例间的相似度函数, 新案例与历史案例 C_k 的相似值为:

$$f(X, C_k) = \sum_{l=1}^n \zeta_l \sqrt{\sum_{j=1}^m (x_j^l - v_{k,j}^l)^2} \quad (5)$$

其中, ζ_l 为第 l 个特征的权值, $\sum_l \zeta_l = 1$ 。

根据式 (5) 计算出的相似值 f , 可得匹配案例为:

$$\arg \min_{C_k} (f(X, C_k)), k=1, 2, \dots, L \quad (6)$$

3 基于 CBRCQL 的分布式认知无线电资源分配算法

3.1 系统模型

本文考虑一个分布式多用户认知无线网络^[12], 网络使用填充式的频谱共享方式。在该方式下, 认知用户不与主用户共享同一信道, 当主用户出现时, 认知用户立即归还信道^[13]。假设认知网络中存在 M 个主用户、 K 个认知用户以及 N 个通信信道。每个主用户分配一个固定信道, 且以概率 λ 在其信道上通信。每个认知用户选择一个信道进行通信, 且同一信道不能同时被多个认知用户占用。在本文算法中, 每个认知用户均被视为一个学习 Agent。

3.2 状态-动作空间、动作策略与奖赏函数的设计

在本文的资源分配算法模型中, 定义状态集只包含一个状态, 即 $S=\{s\}$, 表明所有 Agent 都处于学习状态。因此, 其 Q 值更新式定义如下^[6]:

$$Q_{t+1}^i(a) \leftarrow Q_t^i(a) + \alpha(r_t^i - Q_t^i(a)) \quad (7)$$

其中, $0 < \alpha < 1$ 为学习速率, r_t^i 为执行所选动作后得到的奖赏值。

动作设置考虑信道和功率的联合分配, 即 $a_t = (\text{channel}, \text{power})$, 其中, $\text{channel} \in \{1, 2, \dots, N\}$ 为可用信道; $\text{power} \in P = \{P_1, P_2, \dots, P_z\}$ 为可选功率, z 为可选功率的总类别数。

在 Q 学习算法中, 动作策略是整个学习过程的一个核心部分。动作策略的选择需要解决探索与利用的平衡问题, 不同策略对应的控制参数随时间变化的方式不同, 常用的有 ε -贪婪策略和 Boltzmann 机制。本文选择 Boltzmann 机制作为动作选择策略, 其更新式如式 (8) 所示:

$$\pi(s, a) = \arg \max_a \frac{e^{Q(s, a)/T}}{\sum_k e^{Q(s, a_k)/T}} \quad (8)$$

本文的资源分配算法旨在保证用户正常通信的前提下, 追求认知系统能量效率的最大化。因此设计的奖赏函数定义式如下:

$$r_t^i = \begin{cases} -3, & \text{产生冲突} \\ 0, & \eta^i < \eta^* \\ \Phi^i, & \text{正常传输} \end{cases} \quad (9)$$

其中, η^* 为信干噪比阈值, η^i 为用户 i 在所选信道上传输时的信干噪比, Φ^i 为认知用户 i 的能量效率, 其计算式分别如式 (10)、式 (11) 所示:

$$\eta^i = \frac{p^i h_{ii}(c)}{n_0 + \sum_k g_{ki}(c) p_{pu}^k + \sum_{j \in N \setminus \{i\}} h_{ji}(c) p^j} \quad (10)$$

$$\Phi^i = \frac{W \lg(1 + \eta^i)}{p^i} \quad (11)$$

其中, p^i 为认知用户 i 选择的功率; $h_{ji}(c)$ 为在信道 c 上通信时, 认知用户 j 到认知用户 i 的信道增益; $g_{ki}(c)$ 为在信道 c 上通信时, 主用户 k 到认知用户 i 的信道增益; p_{pu}^k 为主用户 k 的传输功率; n_0 为噪声功率。

3.3 案例特征、效用值与案例更新方法的设计

本文中案例的存储结构由式 (3) 所示的环境

特征参数向量、解决方案和案例效用值 3 部分组成。各案例的环境特征向量 V_k 设置为各用户的信道增益 h_{ki} 和 g_{ki} ；解决方案 Q_k 存储的是各案例学习后的最终 Q 值表。考虑本文算法的目标是使认知系统的能量效率最大化，因此，选择案例效用值 E_k 为各案例达到稳态时的能量效率值。先利用合作 Q 学习的结果建立案例库，在 CBRCQL 算法过程中，新案例学习得到解决方案后，与案例库中效用值最小的案例进行比较，若新案例的效用值小于最小效用值，则不更新案例库；若新案例的效用值大于最小效用值，则删除最小效用值对应的案例记录，并将新案例按格式存储到案例库中，完成案例更新。

3.4 算法步骤

综上，本文提出的基于案例推理与合作 Q 学习的分布式认知无线电资源分配算法 (CBRCQL) 具体流程如下。

(1) 随机初始化 20 组信道增益值，给定 α 、 δ 、 λ 、 T_0 和总迭代次数 G ，根据第 2.2 节中 CQL 算法流程进行学习，然后，按式 (3) 的案例格式存储在案例库中。

(2) 根据当前新问题的信道增益和案例库中各案例的信道增益，利用式 (5) 和式 (6) 取得匹配案例的 Q 值表，然后归一化作为迭代的初始 Q 值。

(3) Agent 根据式 (8) 选择动作 a_t ，实现资源分配。

(4) 由所选的动作，根据式 (9) 计算奖赏值，判断 $\sum_i r_t^i$ 和 $\sum_i r_{t-1}^i$ 的大小。若 $\sum_i r_t^i > \sum_i r_{t-1}^i$ ，则由式 (7) 更新 Q 值；若 $\sum_i r_t^i < \sum_i r_{t-1}^i$ ，则由式 (1) 和式 (2) 更新 Q 值，实现合作学习。

(5) $t \leftarrow t+1$ ， T 值按式 (12) 进行更新；

$$T = T_0 - T_0 \times t / G \quad (12)$$

(6) 当 t 达到设定的总迭代次数 G 时，则转步骤 (7)。否则，转步骤 (3)。

(7) 当前案例完成学习后得到解决方案，根

据第 3.3 节中的案例更新方法完成案例库的更新，以便后续新案例可以进行更好的匹配。

(8) 当有新问题到达时，转步骤 (2)。否则结束。

当不考虑案例更新，即步骤 (7) 为空操作时，上述算法简记为 CBRCQLu。

4 算法仿真和性能分析

4.1 基于合作 Q 学习 (CQL) 算法的性能

设定主用户数 $M=3$ ， λ 为 0.8，其传输功率为 200 mW，信道数 $N=10$ ，信道带宽 W 为 1.5 MHz，各信道增益服从均值为 1 的瑞利分布；认知用户数 $K=3$ ，其可选的传输功率 $P_i \in \{100, 125, 150, 175, 200\}$ mW；信干噪比阈值 η^* 为 0 dB，噪声功率 $n_0 = 10^{-7}$ mW，温度参数初值 $T_0=0.6$ ， α 为 0.2，总迭代次数 G 为 10 000，均分为 20 个学习阶段进行统计。仿真结果均取 10 个新案例实验的平均值。

(1) δ 对系统性能的影响

δ 分别取 0.35、0.55、0.75 和 0.95 时，应用本文 CQL 算法的认知系统能量效率变化如图 4 所示。由图 4 可见，当 $\delta < 0.55$ 时，能量效率的稳态值随 δ 的增加而增加；当 $\delta > 0.55$ 时，能量效率的稳态值随 δ 的增加而减小。当 $\delta < 0.75$ 时，能量效率曲线的收敛速度随 δ 的增加而明显增加；




图 4 能量效率随 δ 的变化



当 $\delta > 0.75$ 时, 能量效率曲线的收敛速度随 δ 的增加而几乎不变。因此, 为平衡能量效率和收敛速度, 下文仿真取 $\delta = 0.75$ 。

(2) 算法性能对比

应用本文的CQL算法、WoLF Q学习算法^[6]和IQL算法^[5]3种算法的认知系统能量效率和认知用户的成功传输概率曲线分别如图5和图6所示。由图6可见, 3种算法最终都能使系统的成功传输概率达到1, 保证用户的正常通信。利用本文CQL算法进行资源分配, 在2 000次迭代后, 系统达到了稳定状态, 系统能量效率的稳态值和收敛速度明显高于其他两种算法。因此, CQL算法能更快地为认知用户分配信道和传输功率, 且能为认知用户提供更高质量的服务。




图5 系统能量效率






图6 系统成功传输概率

(3) 主用户数变化对算法能量效率的影响

当信道数 N 分别为10和16时, 主用户数变化对应于本文的CQL算法、WoLF Q学习算法和IQL算法的系统能量效率影响曲线如图7所示。由图7可见, 3种算法的能量效率都随主用户数的增加呈下降趋势, 这是因为当信道数不变时, 随着主用户数增大, 认知用户可用的信道数减小, 导致认知用户与主用户以及认知用户间的冲突概率增加, 即认知用户受到的干扰增加。当主用户数与认知用户数之和小于 N 时, CQL算法的认知用户间通过相互借鉴学习经验, 可以有效避免冲突产生, 减小其变化带来的影响, 能量效率下降趋势平缓, 且其能量效率最高; 当主用户数与认知用户数之和大于 N 时, 用户间产生冲突, 导致3种算法的能量效率大幅度下降, CQL算法的能量效率略低于WoLF Q学习算法, 但明显高于IQL算法。



(a) $N=10$



(b) $N=16$

图7 能量效率随主用户数变化

4.2 本文提出的 CBRCQL 算法性能

参数设置同第 4.1 节所述实验, 取 $n=2$, $\zeta_1=0.8$, $\zeta_2=0.2$, 分别对应信道增益特征 h_{ii} 和 g_{ki} ; 案例库中的案例数为 20, 总迭代次数 G 为 5 000, 均分为 20 个学习阶段进行统计。

(1) 案例相似值 f 对能量效率的影响

选取当前问题与案例库中案例的相似值 f 分别为 0.052 0、0.325 4 和 0.566 3 时, 应用 CBRCQLu 算法的系统能量效率的变化曲线如图 8 所示。由图 8 可见, f 越小, 当前问题与案例库中的案例越相似, 算法的初始能量效率越大, 收敛速度越快, 且系统能量效率的稳态值也越大。因此, 案例匹配时要选择 f 最小的案例来初始化 Q 值。




图8 相似值 f 对能量效率的影响

(2) 算法性能对比

应用本文的 CBRCQL 算法、CBRCQLu 算法和 CQL 算法的系统能量效率和成功传输概率变化曲线分别如图 9 和图 10 所示。由图 9 可见, CBRCQL 算法在迭代初期的能量效率已经非常接近最佳值, 系统成功传输概率的初始值也比 CQL 算法高很多, 能量效率的稳态值也有提高, 且能够很快收敛。同时, 算法考虑案例更新时, 可以使新案例得到更好的匹配, 且比不考虑案例更新能达到更高的能量效率和更快的收敛速度。

综上所述, 与 WoLF Q 学习算法和独立 Q 学习算法相比, 本文提出的基于案例推理与合作 Q

学习算法能量效率高, 收敛速度快, 可以快速实现多用户认知无线网络的信道和功率的动态分配。




图9 能量效率变化曲线




图10 成功传输概率变化曲线

5 结束语

针对分布式认知无线网络的信道和功率分配问题, 本文提出一种基于案例推理与合作 Q 学习算法, 通过匹配当前问题与案例库中的案例, 使合作 Q 学习算法在迭代初就具有接近最优解的 Q 初值, 减少了不必要的试错实验, 大大提高了算法的收敛速度。仿真结果表明, 基于案例推理与合作 Q 学习算法相比 WoLF Q 学习算法和独立 Q 学习算法能更快完成认知网络的资源分配, 并且能达到更高的系统能效。



参考文献:

- [1] 罗骥. 基于自适应中继的认知协作网络功率分配[J]. 计算机工程, 2017, 43(7): 151-155.
LUO J. Cognitive cooperative network power allocation based on adaptive relay[J]. Computer Engineering, 2017, 43(7): 151-155.
- [2] HE J, PENG J, JIANG F, et al. A distributed Q learning spectrum decision scheme for cognitive radio sensor network[J]. International Journal of Distributed Sensor Networks, 2015: 1-10.
- [3] MOROZS N, CLARKE T, GRACE D. Distributed heuristically accelerated Q-Learning for robust cognitive spectrum management in LTE cellular systems[J]. IEEE Transactions on Mobile Computing, 2016, 15(4): 817-825.
- [4] 李晓静. 基于强化学习的动态频谱分配算法研究[D]. 南京: 南京邮电大学, 2011.
LI X J. The study of the dynamic spectrum allocation algorithm based on reinforcement learning[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2011.
- [5] BOUMEDIENE L, ZGEN G G, LIU S. Distributed multi-agent Q-learning for joint channel allocation and power control in cognitive radio networks[J]. Journal of Computational Information Systems, 2012, 8(17): 7071-7078.
- [6] MOROZS N, CLARKE T, GRACE D. Distributed Q-learning based dynamic spectrum management in cognitive cellular systems: choosing the right learning rate[C]//2014 IEEE Symposium on Computers and Communication, June 23-26, 2014, Funchal, Portugal. Piscataway: IEEE Press, 2014: 1-10.
- [7] CHO B, KIM K J, CHUNG J W. CBR-based network performance management with multi-agent approach[J]. Cluster Computing, 2017, 20(1): 1-11.
- [8] 张文柱, 周雪婷, 刘玉琦. 认知无线电 NC-OFDM 中基于案例推理的无线资源分配[J]. 移动通信, 2017, 41(14): 82-88.
ZHANG W Z, ZHOU X T, LIU Y Q. Radio resource allocation based on case-reasoning in NC-OFDM systems for cognitive radio[J]. Mobile Communication, 2017, 41(14): 82-88.
- [9] 冯陈伟, 袁江南. 基于强化学习的异构无线网络资源管理算法[J]. 电信科学, 2015, 31(8): 99-106.
FENG C W, YUAN J N. Heterogeneous wireless network resource management algorithm based on reinforcement learning[J]. Telecommunications Science, 2015, 31(8): 99-106.
- [10] CHI C, ZHANG Q Z, BO X et al. A multi-agent reinforcement learning algorithm based on Stackelberg game[C]//IEEE 6th Data Driven Control and Learning Systems Conference, May 26-27, 2017, Chongqing, China. Piscataway: IEEE Press, 2017: 727-732.
- [11] 赖海超, 赵知劲, 郑仕链. 应用案例推理技术的快速认知引擎[J]. 信号处理, 2012, 28(12): 1700-1705.
LAI H C, ZHAO Z J, ZHENG S L. Fast cognitive engine using case-based reasoning[J]. Signal Processing, 2012, 28(12): 1700-1705.
- [12] LALL S, SADHU A K, AMIT K. Multi-agent reinforcement learning for stochastic power management in cognitive radio network[C]//International Conference on Microelectronics, Computing and Communications, Jan 23-25, 2016, Durgapur, India. Piscataway: IEEE Press, 2016: 1-6.
- [13] 曾庆瑾. 认知无线电动态频谱的分配和接入问题研究[D]. 南宁: 广西大学, 2015.
ZENG Q J. Study on the allocation and access of the dynamic frequency spectrum for cognitive radio[D]. Nanning: Guangxi University, 2015.

[作者简介]



徐琳(1994-), 女, 杭州电子科技大学通信工程学院硕士生, 主要研究方向为认知无线电、信号处理。



赵知劲(1959-), 女, 博士, 杭州电子科技大学教授、博士生导师, 主要研究方向为认知无线电、通信信号处理和自适应信号处理等。