

一种最大置信上界经验采样的深度 Q 网络方法

朱斐^{1,2,3} 吴文¹ 刘全^{1,3} 伏玉琛^{1,4}

¹(苏州大学计算机科学与技术学院 江苏苏州 215006)

²(江苏省计算机信息处理技术重点实验室(苏州大学) 江苏苏州 215006)

³(符号计算与知识工程教育部重点实验室(吉林大学) 长春 130012)

⁴(常熟理工学院计算机科学与工程学院 江苏常熟 215500)

(zhufei@suda.edu.cn)

A Deep Q-Network Method Based on Upper Confidence Bound Experience Sampling

Zhu Fei^{1,2,3}, Wu Wen¹, Liu Quan^{1,3}, and Fu Yuchen^{1,4}

¹(School of Computer Science and Technology, Soochow University, Suzhou, Jiangsu 215006)

²(Provincial Key Laboratory for Computer Information Processing Technology (Soochow University), Suzhou, Jiangsu 215006)

³(Key Laboratory of Symbolic Computation and Knowledge Engineering (Jilin University), Ministry of Education, Changchun 130012)

⁴(School of Computer Science and Engineering, Changshu Institute of Technology, Changshu, Jiangsu 215500)

Abstract Recently, deep reinforcement learning (DRL), which combines deep learning (DL) with reinforcement learning (RL) together, has become a hot topic in the field of artificial intelligence. Deep reinforcement learning has made a great breakthrough in the task of optimal policy solving with high dimensional inputs. To remove the temporary correlation among the observed transitions, deep Q-network uses a sampling mechanism called experience replay that replays transitions at random from the memory buffer, which breaks the relationship among samples. However, random sampling doesn't consider the priority of sample's transition in the memory buffer. As a result, it is likely to sample data with insignificant information excessively while ignoring informative samples during the process of network training, which leads to longer training time as well as unsatisfactory training effect. To solve this problem, we introduce the idea of priority to traditional deep Q-network and put forward a prioritized sampling algorithm based on upper confidence bound (UCB). It determines sample's probability of being selected in memory buffer by reward, time step, and sampling times. The proposed approach assigns samples that haven't been chosen, samples that are more valuable, and samples that have good results, with higher probability of being selected, which guarantees the diversity of samples, such that the agent is able to select action more effectively. Finally, simulation experiments of Atari 2600 games verify the approach.

收稿日期:2018-03-06;修回日期:2018-06-01

基金项目:国家自然科学基金项目(61303108,61373094,61772355);江苏省高校自然科学研究重大项目(17KJA520004);符号计算与知识工程教育部重点实验室(吉林大学)资助项目(93K172014K04);苏州市应用基础研究计划工业部分(SYG201422);高校省级重点实验室(苏州大学)项目(KJS1524);中国国家留学基金项目(201606920013)

This work was supported by the National Natural Science Foundation of China (61303108, 61373094, 61772355), Jiangsu College Natural Science Research Key Program (17KJA520004), the Program of the Key Laboratory of Symbolic Computation and Knowledge Engineering of Ministry of Education (Jilin University) (93K172014K04), Suzhou Industrial Application of Basic Research Program (SYG201422), the Program of the Provincial Key Laboratory for Computer Information Processing Technology (Soochow University) (KJS1524), and China Scholarship Council Project (201606920013).

通信作者:伏玉琛(yuchenfu@cslg.edu.cn)

Key words reinforcement learning (RL); deep reinforcement learning (DRL); upper confidence bound; experience replay; deep Q-network (DQN)

摘要 由深度学习(deep learning, DL)和强化学习(reinforcement learning, RL)结合形成的深度强化学习(deep reinforcement learning, DRL)是目前人工智能领域的一个热点。深度强化学习在处理具有高维度输入的最优策略求解任务中取得了很大的突破。为了减少转移状态之间暂时的相关性,传统深度Q网络使用经验回放的采样机制,从缓存记忆中随机采样转移样本。然而,随机采样并不考虑缓存记忆中各个转移样本的优先级,导致网络训练过程中可能会过多地采用信息较低的样本,而忽略一些高信息量的样本,结果不但增加了训练时间,而且训练效果也不理想。针对此问题,在传统深度Q网络中引入优先级概念,提出基于最大置信上界的采样算法,通过奖赏、时间步、采样次数共同决定经验池中样本的优先级,提高未被选择的样本、更有信息价值的样本以及表现优秀的样本的被选概率,保证了所采样本的多样性,使智能体能更有效地选择动作。最后,在Atari 2600的多个游戏环境中进行仿真实验,验证了算法的有效性。

关键词 强化学习;深度强化学习;最大置信上界;经验回放;深度Q网络

中图法分类号 TP18

强化学习(reinforcement learning, RL)能完成从环境状态到动作映射的自我学习过程^[1],智能体(agent)与环境交互,选择并执行动作,环境对此作出反应,进入下一个状态,利用价值函数评估状态,不断调整策略,反复迭代,直到结束。强化学习通过寻求agent在环境中获得的最大累积奖赏值,获得最优策略。强化学习是目前机器学习领域的研究热点之一,已经在优化调度、游戏博弈等领域中得到了良好的应用^[2-4]。深度学习(deep learning, DL)是机器学习的另一个研究热点,其基本思想是自主地从原始输入数据中组合底层特征,形成更抽象的高层来表示属性类别或特征。深度学习的一些方法已经成功地应用于图像处理、自然语言处理等多个领域^[5-7]。

目前,越来越多的任务以复杂数据为输入,以求解最优策略为目标。这就需要将深度学习和其他机器学习方法结合起来。谷歌人工智能团队DeepMind将深度学习和强化学习结合在一起,形成了深度强化学习(deep reinforcement learning, DRL),开启了从感知到决策的端对端(end to end)的研究。深度Q网络(deep Q-network, DQN)^[8-9]是深度强化学习的一个著名方法,其结合了深度卷积神经网络(convolutional neural network, CNN)和强化学习中的Q学习(Q-learning)算法^[10],成功地用于解决高维输入环境中学习策略的任务。深度Q网络方法可以将未经处理的图片直接作为输入,在处理视觉控制问题中具有通用性;在一些Atari 2600游戏中,深度Q网络达到了能与人类玩家媲美的水平。

可是,传统的强化学习算法存在着一些问题,使之不能很好地与深度学习方法结合。例如,在传统的强化学习算法中,每观察到一次状态转移就要更新一次参数。这会带来2个问题:1)参数更新在时间上是相关的;2)出现次数少的转移样本容易被忽视。而大多数深度学习算法需要满足2个重要条件:1)训练样本之间的关联程度低;2)训练样本在训练期间可以被重复使用多次。经验回放(experience replay)方法可以较好地解决这些问题^[11-12]。经验回放方法将历史样本放到经验池中,每次选择小批量(mini-batch)样本计算损失函数并更新网络参数。深度Q网络也使用了经验回放方法,agent可以在线地存储和使用其与环境交互得到的历史样本。在每个时刻,agent等概率地抽取小批量的转移样本进行训练,以保证小概率出现的样本也能够有机会保存在经验池中。经验回放方法打破了学习样本中存在的关联性,不仅使训练过程更易于收敛,而且提高了数据的利用率。但是,经验回放方法仅简单地使用等概率的方式对经验池中的数据进行采样。事实上,在经验池中的转移样本对参数训练的作用是有所不同的:有些转移样本会产生较大的作用,有些则反之。而经验回放方法的采样方式很难区分不同样本的重要性。Schaul等人^[13]提出一种基于时间差分误差(temporal difference error, TD-error)的优先经验回放(prioritized experience replay, PER)的采样方式,以TD-error评估样本,认为TD-error大的样本重要性程度高,应赋予较高的被选概率。该方法能更好地利用经验池中的重要样本,但是由于经验池

容量通常是固定的,且训练时采用的批量样本数量较少,因此会存在一些样本未被使用就被舍弃的情况。这一不足使得样本多样性的要求无法得到满足,结果使得学习效率低下。

针对此问题,本文提出了一种新型的采样机制,有效地避免了上述问题。一方面,在采样过程中利用最大置信上界(upper confidence bound, UCB)的基本思想^[14],提出了基于最大置信上界采样算法(upper confidence bound sample, UCBS),给经验池中未被使用过的样本附加一个鼓励项,提高其被选取的概率,从而保证样本的多样性;另一方面,增加能使agent学习到更多信息的样本的被选概率。由于本文方法使用奖赏值来衡量agent从样本中学习信息的优劣,因此,本文方法会倾向于选择可能获得更高奖赏样本,进而使agent能够更快地学习到最优策略。

1 相关工作

1.1 强化学习

在强化学习中,agent与未知的环境交互以期望获得最大的累积奖赏。一般使用Markov决策过程(Markov decision process, MDP)模型对强化学习问题进行建模。一个MDP问题可以用一个四元组(X, U, P, R)表示,其中: X 是所有状态集合, $x_t \in X$ 表示时间步 t 环境的状态; U 是所有动作集合, $u_t \in U$ 表示agent在时间步 t 所采取的动作; P 是状态迁移函数,通常形式化表示为 $P(x_{t+1} | x_t, u_t)$,表示在时间步 t ,agent采取动作 u_t 从当前状态 x_t 迁移到下一状态 x_{t+1} 的概率,且满足 $\sum_{x_{t+1} \in X} P(x_{t+1} | x_t, u_t) = 1$; R 是奖赏函数,通常表示为 $r_{t+1} = R(x_t, u_t, x_{t+1})$,表示agent在状态 x_t 处采取动作 u_t ,迁移到下一状态 x_{t+1} 后所获得的立即奖赏 r_{t+1} 。

在强化学习中,从时间步 t 开始到时间步 T 情节结束时所获得的累积折扣奖赏定义为

$$R_t = \sum_{k=t}^T \gamma^{k-t} r_k, \quad (1)$$

其中, $0 \leq \gamma \leq 1$ 是折扣因子,表示未来奖赏对累积奖赏的影响力度。

在强化学习模型下,agent在时间步 t 的状态 x_t 下,执行根据策略 h 选择动作 u ,环境对智能体所执行的动作给出反馈,给agent下一时间步的状态 x_{t+1} 和奖赏 r_{t+1} 。强化学习模型框架示意图如图1所示:




Fig. 1 The diagram of reinforcement learning framework
图1 强化学习模型框架示意图

在强化学习中,可以使用状态动作值函数来评估策略。状态动作值函数 $Q^h(x, u)$ 是指依据策略 h ,在当前状态 x_t 下执行动作 u_t ,直到情节结束所获得的累积奖赏之和, $Q^h(x, u)$ 可以表示为

$$Q^h(x, u) = E[R_t | x_t = x, u_t = u, h], \quad (2)$$

其中, E 表示期望。

状态动作值函数 $Q^h(x, u)$ 遵循贝尔曼方程。根据贝尔曼方程获得的时间步 $t+1$ 的状态动作值 $Q_{t+1}(x, u)$ 为

$$Q_{t+1}(x, u) = E_{x_{t+1} \sim X} [r + \gamma \max_{u_{t+1}} Q_t(x_{t+1}, u_{t+1}) | x, u], \quad (3)$$

其中, $Q_t(x, u)$ 是时间步 t 的状态动作值。利用贝尔曼方程不断迭代,状态动作值最终收敛,从而得到最优策略。

根据状态迁移函数 P 是否已知,强化学习可以分为基于模型的动态规划算法和基于无模型的强化学习算法;根据生成行为的策略和更新值函数是否相同,基于无模型的强化学习算法又分为同策略算法(on-policy)和异策略(off-policy)算法。深度Q网络方法所用到的Q-learning算法就是一种典型的异策略算法^[15]。Q-learning算法的更新公式为

$$\delta = r_{t+1} + \gamma \max_u Q(x_{t+1}, u) - Q(x_t, u_t), \quad (4)$$

$$Q(x_t, u_t) = Q(x_t, u_t) + \alpha \delta, \quad (5)$$

其中, γ 为折扣因子, δ 为TD-error。Q-learning算法所学到的动作值函数是直接逼近最优动作值函数而不依赖于其策略,简化了算法的分析。

在解决实际任务时,由于状态空间过于庞大和复杂,通过迭代贝尔曼方程来求解最优策略的可行性不高。因此,通过一般利用对大规模的状态空间进行泛化以提高计算效率。很多方法使用函数逼近器来近似表示状态动作值,得到参数化方式表达的值函数,即 $Q(x, u; \theta_t)$,其中, θ_t 为参数向量,其更新方式

为 $\theta_{t+1} = \theta_t + \alpha \delta \nabla_{\theta_t} Q(x_t, u_t; \theta_t)$. 然而, 当一些非线型函数逼近器(如深度神经网络)与部分强化学习算法(如 Q 学习算法)相结合时, 会出现值函数 $Q(x, u; \theta)$ 不稳定的情况, 限制了深度强化学习的发展.

1.2 深度学习

深度学习的基础是人工神经网络 (artificial neural network, ANN), 由浅层学习发展而来. 反向传播(back propagation, BP) 算法^[16] 是深度学习的基本算法. 利用反向传播算法可以让一个人工神经网络从大量训练样本中学习到数据的分布式特征, 从而对未知样本进行预测. 由多个隐藏层构成的多层感知器(multi-layer perceptron, MLP) 比浅层网络特征表达的能力更强.

前馈网络是一种常见的神经网络连接方式. 前馈深度神经网络在每一层使用函数将一批输入的集合传输到输出层, 不断地调整网络参数, 优化网络. 卷积神经网络就是一种经典的前馈深度神经网络, 通常包括卷积层、池化层和全连接层. 卷积神经网络可以以图片等高维数据为直接输入, 采用局部连接和共享权值的方式, 减少了权值的数量, 使得网络易于优化, 也降低了过拟合的风险. Krizhevsky 等人^[17] 提出的深度卷积神经网络使用非线性激活函数整流线性单元(rectified linear unit, ReLU), 加快了收敛速度并抑制了梯度消失问题. 由于其采用纯粹的

监督学习训练方式, 代替了“预训练十微调”的方式, 引起了基于卷积神经网络的深度学习研究热潮, 如 Simonyan 等人^[18] 提出的模型进一步提高了图像的识别能力; He 等人^[19] 提出了有 152 层深度的深度残差网络(deep residual network, DRN).

循环神经网络(recurrent neural network, RNN) 隐藏层的结点有存储历史信息的功能, 常被用于处理具有时序特性的问题^[20]. 循环神经网络可以看成是一个共享同一参数的多层网络, 然后再根据时间序列展开计算. 虽然循环神经网络可以“记忆”历史信息, 但是它难以保存相隔时间较长的信息. 但是, 循环神经网络存在梯度消失的不足. 针对这些问题, 研究人员提出了长短期记忆网络(long short-term memory, LSTM) 和门限循环单元^[21] (gated recurrent unit, GRU), 弥补了循环神经网络存在的缺陷. 此外, 还有一些研究人员运用其他的机制来改进循环神经网络, 如将结合注意力机制与循环神经网络, 使得网络能记住历史信息中的关键部分^[22].

1.3 深度 Q 网络

Mnih 等人^[9] 在传统强化学习中的 Q 学习算法和深度卷积神经网络的基础上提出了深度 Q 网络, 用于处理基于视觉的控制任务, 缓解了用非线性函数逼近器表示值函数时算法的不稳定性. 深度 Q 网络结构示意图如图 2 所示:




Fig. 2 The diagram of the architecture of deep Q network

图 2 深度 Q 网络结构示意图

深度 Q 网络的输入是已经被预处理的 4 幅 84×84 图片. 第 1 层卷积层有 32 个 8×8 卷积核对图片进行卷积操作, 卷积步幅为 4; 第 2 层卷积层有 64 个 4×4 的卷积核, 卷积步幅为 2; 最后一层卷积层有 64 个 3×3 的卷积核, 卷积步幅为 1. 每一层卷积层后都有 1 个非线性激活函数 ReLU, 在 3 层卷积层后跟着 2 个全连接层, 第 1 个全连接层拥有 512 个结点, 第 2 个全连接层的结点数与动作数量一致.

深度 Q 网络方法主要有 2 点改进: 1) 使用了经验回放方法, 在每一个时间步 t , agent 将与环境交

互产生的转移样本 $e_t = (x_t, u_t, r_t, x_{t+1})$ 存储到经验池 $D_t = \{e_1, e_2, \dots, e_t\}$ 中. 采用等概率方式在经验池中抽取出相同数量的转移样本. 经验回放方法可以打破样本之间的关联性, 使深度 Q 网络能处理很多任务, 如控制 Atari 2600 游戏. 2) 使用了 2 个网络来分别表示当前值函数和目标值函数, 其中, 采用实时方式更新当前值网络参数 θ , 而目标值网络参数 θ^- 则在 L 步后通过复制当前值网络参数 θ 得到. 在每一时间步 t , 通过不断减小目标值函数和当前值函数之间的均方误差来更新参数 θ , 损失函数为

$$L_t(\boldsymbol{\theta}_t) = E[(r + \gamma \max_{u_{t+1}} Q(x_{t+1}, u_{t+1}; \boldsymbol{\theta}_t^-) - Q(x, u; \boldsymbol{\theta}_t))^2], \quad (6)$$

进一步得到

$$\nabla_{\boldsymbol{\theta}_t} L_t(\boldsymbol{\theta}_t) = (r + \gamma \max_{u_{t+1}} Q(x_{t+1}, u_{t+1}; \boldsymbol{\theta}_t^-) - Q(x, u; \boldsymbol{\theta}_t)) \nabla_{\boldsymbol{\theta}_t} Q(x, u; \boldsymbol{\theta}_t). \quad (7)$$

式(7)并不需要计算所有的梯度,只要计算合适批量来优化损失函数。因此,可以选用随机梯度下降的方法来计算。网络参数根据损失函数梯度下降的方向调整

$$\boldsymbol{\theta}_{t+1} = \boldsymbol{\theta}_t + \alpha \nabla_{\boldsymbol{\theta}_t} L_t(\boldsymbol{\theta}_t). \quad (8)$$

深度 Q 网络使用离策略,即通过贪心策略 $u_{t+1} = \max_{u_t} (x_t, u_t; \boldsymbol{\theta}_t)$ 估计最优 Q 值,选择动作采用 ϵ -贪心 (ϵ -greedy) 方法:以 $1-\epsilon$ 的概率选择贪心动作,以 ϵ 的概率选择随机动作。

近年来,出现了以深度 Q 网络为基础的各种改进模型。针对强化学习算法 Q-learning 会出现乐观估计动作值的问题,Van Hasselt 等人^[23]在双 Q 学习算法(double Q-learning)^[24]的基础上提出了深度双 Q 网络(double deep Q-network, DDQN)。该方法在计算目标网络的 Q 值时使用了 2 套不同的参数,有效地避免了深度 Q 网络过高估计动作值的问题。深度 Q 网络通过采用重复 4 次相同动作减少动作选择以有利于下一个状态。Lakshminarayanan 等人^[25]根据当前状态重要性有所不同的特点,提出了动态跳帧的方法重复动作,有效地提高了模型的训练效果。Wang 等人^[26]将深度 Q 网络中卷积神经网络所提取的特征分为优势函数(advantage function)和与动作无关的状态值函数,使用这 2 个函数来生成状态值函数,提出了竞争深度 Q 网络(dueling deep Q-network, DuDQN),在不改变底层强化学习算法的情况下进一步提高了深度 Q 网络的效果。

上述这些改进后的模型都是基于卷积神经网络的。从卷积神经网络的结构来看,每层神经元的信号只能向上一层传播,因此,如果不同时刻的子任务之间存在依赖关系,这些模型的效果表现就一般。Narasimhan 等人^[27]提出了深度循环 Q 网络(deep recurrent Q-network, DRQN),首次引入了长短期记忆网络^[28],在处理一些带有时序性的文本任务中表现良好。在此基础上,Hausknecht 等人^[29]提出了深度循环 Q 学习算法(deep recurrent Q-learning, DRQ),在处理部分可观测 Markov 决策过程(partially observable Markov decision process, POMDP)问题时取得了良好的效果。

2 基于最大置信上界采样的深度 Q 网络模型

2.1 基于最大置信上界采样

在深度 Q 网络中,等概率采样不能充分利用有价值的转移样本;而且在有限的经验池中,等概率采样存在重复采用低价值样本、遗漏重要样本等问题,导致学习效率低下。

在强化学习中,研究人员通常认为那些取得较大奖赏的动作可以加速模型的学习,因此,本文增加了选取具有较大奖赏的动作的概率。然而,随着选择较大奖赏动作的概率逐渐提高,选取其他动作的概率就会不断降低,这就有可能使算法陷入局部最优;而且这样做也无法保证样本多样性的要求。因此,亟需一种既可以充分利用大奖赏动作又能保证样本多样性的方法。

在强化学习中,由于动作值函数的估计值是未知的,因此需要进行适当的探索。贪心(greedy)方法选择当前状态下获得立即奖赏最多的动作。但是,贪心方法有可能会遗漏其他使得累积奖赏更大的动作。为了增加探索到未被发现的优秀动作的概率,常常使用 ϵ -贪心方法选择动作。然而, ϵ -贪心方法未区分非贪心动作实际存在的差异。Auer 等人^[14]提出了使用最大置信上界(UCB)思想解决多臂赌博机(multi-armed bandit)问题,在当前时刻选择最优动作和选择未来最优动作之间进行了优化,有效地平衡了探索和利用的关系。受到该方法的启发,针对经验重放方法所存在的问题,本文提出一种基于最大置信上界的优先级采样方法,通过提高奖赏较大的动作的被选概率,有效地增加了经验池中重要样本被采样的可能性;另一方面,通过提高未被选取样本的被选概率,保证了数据采样的多样性。本文将上述采样方法应用于深度 Q 网络,构建了一个基于最大置信上界采样的深度 Q 网络(upper confidence bound sampling deep Q-network, UCBS-DQN),总体结构如图 3 所示。

在 UCBS-DQN 方法中,当前值网络的输入是经过灰度处理后的图片,这些图片经过网络的训练后得到当前动作值函数,与目标值网络中的最大动作值函数形成误差函数,使用基于均方根的传播方法(root mean square propagation, RMSProp)最小化误差函数;从经验回放单元提取经过处理后选择的样本,选择动作;每间隔 L 步(通常 L 取较大值)将当前值网络参数复制给目标值网络参数。图 3 中




Fig. 3 The diagram of the architecture of UCBS-DQN

图 3 UCBS-DQN 结构示意图

的虚线部分是本文的改进之处。在每一次执行动作后,计算样本的优先级并进行归一化操作,给经验池中的样本赋予优先级,更新网络所用样本通过样本特征抽取获得。从图 3 中可以看到,本文方法在从经验回放单元中抽取样本时利用最大置信上界的思想,用新的方法给样本赋予优先级。对于每个样本的选取概率更新公式为

$$p_i = p_i + c(r_i + \sqrt{\ln t / N_i}), \quad (9)$$

$$p_i = \frac{p_i}{\sum_{j=1}^N p_j}, \quad (10)$$

其中, p_i 是选取第 i 个样本的概率; 初始时, 所有样本被选取的概率相等, 即 $p_i = p_j$ ($i, j \in [1, N]$) 且满足 $\sum_{i=1}^N p_i = 1$, N 为样本总个数; 每个时间步后对所有样本的被选取概率进行归一化操作, 如式(10)所示; r_i 是选择第 i 个样本可以得到的奖赏值; t 是时间步, 记录了从开始采样到当前状态的步数; N_i 为第 i 个样本被选取的次数; c 是调节优先级对其选择动作影响大小的参数, 当 $c=0$ 时, 以等概率方式选取样本。

式(9)中加入了样本选取的不确定估计机制。当第 i 个样本被选择后, 由于 N_i 出现在平方根项的分母上, 因此, 该样本被选概率会随着时间步而逐渐降低。另一方面, 随着训练的进行, 时间步 t 逐渐增加, 其他样本在之后时间步被选的概率也会提高。当第 i 个样本中的奖赏为正奖赏时, 即可认为该样本为优秀样本。为了限制奖赏的影响力, 且统一不同实验

中奖赏的度量尺度, 本文将正奖赏设置为 1, 负奖赏设置为 -1。这样既提高了奖赏较大的样本被选概率, 又降低了奖赏较低样本的出现概率。随着步数的增加, 时间步 t 的影响会越来越大。为了减缓时间步 t 的增长速度, 更新式(9)中使用了对数函数, 使时间步的影响力小于样本获得奖赏大小的影响力。本文方法还考虑了信息量较大的样本以及未被选择的样本, 保证了样本的多样性。

2.2 算法描述及分析

本文将基于最大置信上界的优先级采样应用于深度 Q 网络, 得到了基于最大置信上界采样的深度 Q 学习方法, 具体描述如算法 1 所示。

算法 1. 基于最大置信上界采样的深度 Q 学习方法(UCBS-DQN).

① 初始化: 经验回放单元 D 中的容量 N ; 抽样样本数量 minibatch 的大小为 32; 每个样本初始概率 $p_i = 1/N, i \in [1, N]$; 当前值网络的参数为 θ , 目标值网络的参数为 $\theta^- (\theta = \theta^-)$; 选择随机动作概率为 $\epsilon; i=0$; 时间步 $t=0$.

② Repeat(对每一个情节):

- 初始化并预处理状态序列 $\phi_1 = \phi(x_1)$;
- ③ Repeat(对于情节中的每个时间步):
- ④ 用 ϵ -贪心选择随机动作 u_i ;
- ⑤ 执行动作 u_i , 得到一幅图像 o_{i+1} 和立即奖赏 r_i ;
- ⑥ 设置 $x_{i+1} = x_i, u_i, o_{i+1}$, 并处理得到 $\phi_{i+1} = \phi(x_{i+1})$;
- ⑦ 将 $(\phi_i, u_i, r_i, v_i, \phi_{i+1})$ 作为一个样本存储到 D 中;

- ⑧ Repeat(对每一个批次样本):
- ⑨ 随机在[0,1]之间取值 $random()$;
- ⑩ 若 $\sum_{k=1}^n p_k \leqslant random() < \sum_{k=1}^{n+1} p_k$, 则从 D 中抽取第 k 个样本;
- ⑪ Until 批次结束
- ⑫ 若达到终止状态, 则 $y_i = r_i$;
- ⑬ 否则设置为 $y_i = r_i + \gamma \max_{u_{i+1}} Q(\phi_{i+1}, u_{i+1} | \theta^-)$;
- ⑭ $i = i + 1, t = t + 1$;
- ⑮ 变更该样本的优先级

$$p_i = p_i + c \left(r_i + \left(\frac{\ln t}{N_i} \right)^{\frac{1}{2}} \right);$$
- ⑯ 将样本被选概率归一化 $p_i = \frac{p_i}{\sum_{j=1}^n p_j}$;
- ⑰ 对损失函数 $L(\theta) = (r + \gamma \max_{u_{i+1}} Q(x_{i+1}, u_{i+1} | \theta^-) - Q(x_i, u_i | \theta))^2$ 的 θ 进行梯度下降操作以更新参数 θ ;
- ⑯ 每 L 步更新目标值网络的参数 $\theta^- \leftarrow \theta$;
- ⑯ Until 智能体达到终止状态
- ⑯ Until 达到预期训练次数 M
- ⑯ Return 当前值网络参数 θ 和目标值网络参数 θ^- .

在算法 1 中, 步⑨~⑩是基于最大置信上界采样算法采样的过程, 通过优先级计算, 每个样本的被选概率不同; 步⑯~⑯是产生优先级的过程, 根据样本的奖赏和被选次数设计优先级; 步⑰计算损失函数的梯度。

2.3 复杂度分析

UCBS-DQN 方法大致可以分为优先级标签提取、计算优先级和模型求解 3 个阶段, 下面从这 3 个角度分析模型复杂度。

1) 优先级标签提取阶段. 在 UCBS-DQN 方法中, 每一个情节中包含了若干时间步, 在每个时间步中提取样本优先级标签以更新网络参数. 当经验池容量满后不再变化, 其大小为常数. 每个训练批次提取样本的数量为 32, 因此, 提取样本优先级时模型空间复杂度为 $O(1)$, 时间复杂度都为 $O(n)$. 此外, 在 UCBS-DQN 方法中, 需要从经验池中抽取样本送入网络进行训练以更新参数, 模型参数每隔 L 步更新一次且 L 取值较大(实验中 $L = 10000$), 其余时刻大部分用于执行优先级更新操作, 因此网络参数更新时间复杂度和空间复杂度都为 $O(1)$.

2) 计算优先级阶段. 优先级的计算是在游戏每个执行动作之后, 对经验池中样本优先级进行计算, 在计算其优先级时需要遍历每一个样本, 再由样本被选概率更新方式得到计算优先级的时间复杂度为 $O(n)$. 由于样本上限为常数, 因此其空间复杂度为 $O(1)$.

3) 模型求解阶段. 整个模型需要重复执行 M 轮, 因此, 在模型求解阶段算法时间复杂度为 $O(n)$.

由于优先级标签提取、计算优先级和模型求解阶段是层层嵌套的, 因此, 整体而言, UCBS-DQN 方法的算法时间复杂度为 $O(n^3)$.

经过复杂度分析可知, 本文提出的 UCBS-DQN 方法能够通过消耗较小的空间和时间代价得到经验池样本优先级, 并通过其被选概率选择样本.

3 实验结果及分析

在本节中, 首先介绍实验所用平台和实验中所用参数; 随后, 对深度 Q 网络(DQN)、深度循环 Q 网络(DRQN)、基于时间差分误差的优先经验回放(PER)以及本文提出的基于最大置信上界采样的深度 Q 学习方法(UCBS-DQN)在部分 Atari 2600 游戏中的表现进行评估; 最后, 结合实验结果和游戏特性分析 UCBS-DQN 方法的优势.

3.1 实验平台及实验介绍

OpenAI 是一家非营利性的人工智能研究公司, 创立初衷是预防人工智能的灾难性影响, 同时为推动人工智能的发展发挥积极作用. OpenAI 公司于 2016 年提出的 Gym 是一种用于开发和比较强化学习和深度强化学习算法的工具包, 提供了各种 Atari 2600 游戏接口, 包括策略类、动作类、桌游类、体育竞技类等 59 种经典游戏. Gym 为人工智能研究人员提供了丰富且具有挑战性的深度强化学习平台. 本文的实验环境基于 Gym 的 Atari 2600 游戏环境.

本文的实验比较了 4 种方法在 4 个 Atari 游戏中的效果, 包括 Seaquest 游戏、Breakout 游戏、Space Invader 游戏和 Assault 游戏. 1) Seaquest 游戏是潜水艇对战游戏, 其奖赏来自于潜水艇击杀潜艇类别和数量, 若被其他潜艇子弹击中, 则游戏结束. 在游戏中, 潜水艇每隔一定时间都需要在海底获得一个一次性的氧气瓶, 然后浮出水面吸收氧气, 当氧气瓶中的氧气耗尽时, 游戏就结束. 2) Breakout 游戏是一种小球击打砖块的游戏, 小球从下方开始击打上方的砖块, 每成功击打一次就获得一个奖赏.

击打的位置不同,所获得的奖赏也不同。通过控制屏幕底端的板块来反弹小球,防止小球掉落,若小球掉落则宣告游戏结束。3) Space Invader 游戏是操控一架只能在一条水平线上的战斗机,消灭在画面中的敌方飞机。若我方战机被对方子弹打中,游戏就结束。4) 在 Assault 游戏中,玩家操控飞机消灭源源不断产生的敌机,随着游戏的过程,敌机速度会越来越快,消灭飞机所获奖赏也会相应提高,若我方飞机被子弹击中,游戏就结束。

本文实验使用 Intel i7-7820X 处理器,使用 GTX 1080Ti 图形处理器对深度学习运算进行辅助加速计算。实验中,使用强化学习模型对 Atari 2600 游戏进行建模,其中,距离时间步 t 最近的 N 幅视频帧构成了状态 $x_t = (s_{t-N+1}, s_{t-N+2}, \dots, s_t) \in X$, agent 从动作集 U 中选择一个动作 $u_t = \{1, 2, \dots, K\} \in U$, 执行后产生新的游戏画面代表 agent 转移到下一状态 x_{t+1} , 2 幅画面的得分差值即为奖赏 r_t 。

3.2 参数设置

本文对比了 DQN, DRQN, PER 以及 UCBS-DQN 方法的性能。实验中,4 种方法均采用 RMSProp 方法更新参数,其动量参数设置为 0.95。

在 Gym 包中,各个游戏所获得的奖赏差异较大,这会影响到最终网络输出的 Q 值,进一步影响动作选择。为了缩小 Q 值的范围,实验中将所有大于 1 的奖赏设置为 1,所有小于 -1 的奖赏设为 -1,处于 [-1, 1] 之间的奖赏值不变。此外,当前网络和目标网络之间的误差项也被控制在 [-1, 1] 之间,这可以防止结果陷入局部最优,提高系统稳定性。

Gym 提供的 Atari 2600 游戏图像像素是 210×160 。为了方便图像处理,将图像像素预处理为 84×84 的灰度图像,并以处理过后的 4 幅图像作为网络输入。训练时,如果一个动作仅执行一次,则会使得策略在空间和时间上变化太快,从而导致网络需要经常选择动作,而选择动作需要根据深度网络进行层层计算得到的结果来判断,造成深度网络计算所用时间远远大于网络前向传播的时间。因此,实验重复采取 4 次当前动作,这样既减少了计算量,又保持了动作序列的多样性。在实现经验回放方法时,由于初始状态的经验池缺乏样本数据,故而在实验的前 50 000 步对经验池进行填充。经验池的容量设置为最大存放 100 万个样本,每次从经验池中取出 32 个样本放入网络进行训练。Q 值更新的折扣率 γ 设置为 0.99。由于在训练后期,训练步幅过大可能会导致算法不收敛,而此时使用 ϵ -贪心方法探索也足以

满足需求,因此,实验中每隔 100 000 步以每次下降 4% 的步长进行衰减:网络更新参数 α 从 0.005 下降到 0.000 25, ϵ -贪心策略的参数 ϵ 从 1 下降到 0.1。

3.3 实验结果分析

在实验中,每种方法使用相同参数:采用 500 个训练阶段,每个训练阶段设置为 10 000 步。图 4 显示了各方法在 4 种不同游戏中所获得的平均奖赏。从图 4 中可以看出,UCBS-DQN 方法的平均每情节奖赏高于其他 3 种方法。

从图 4(a) 中 Seaquest 游戏的平均奖赏图可以发现,面对这种复杂的环境,DQN 和 DRQN 方法表现都不令人满意;PER 方法虽然通过使用 TD-error 优先级提高了每情节奖赏,但需要经历 240 多个训练阶段之后才出现效果的提升;而 UCBS-DQN 方法在第 100 轮训练阶段的平均每情节奖赏就已经是 DQN 方法的 5 倍、DRQN 方法的 4 倍,效果得到了大幅提升。经过分析可知,Seaquest 游戏的上浮吸收氧气情节需要一直执行上浮动作,这些动作在当前阶段得到的反馈较差,但却是必须执行的。因此,DQN 和 DRQN 方法中,这些动作对平均奖赏值的提高作用有限。使用了 TD-error 优先级的 PER 方法虽然比 DQN 和 DRQN 方法表现好,但该方法并不具备很好的探索其他训练样本的机制,导致了其效果需要在较多的训练阶段之后才能得到显著的提升。而 UCBS-DQN 方法增加了那些不常被选择的样本的被选概率,加之引入跳帧机制,使得潜水艇能够以大概率执行上浮动作,保持更长的游戏时间,提高了平均每情节奖赏。

从图 4(b) 中 Breakout 游戏的平均奖赏图可以发现,UCBS-DQN 方法能更快地取得更好的效果,并且在训练过程中的每情节奖赏一直高于其他 3 种方法。但是,UCBS-DQN 方法所获得的提升效果不如 Seaquest 游戏明显。这是因为 Breakout 游戏环境较为简单,其动作除去开局阶段的开球,在游戏过程中只有左右移动和静止,且其状态数量也少于其他游戏,这使得经验池中样本相似性增大。因此,UCBS-DQN 方法使用未被选择的样本来训练,其提升效果就受到限制。而另一方面,由于 Breakout 游戏状态相似性较高,UCBS-DQN 方法可以很快地找到较好的动作值函数,故而在训练到第 100 轮左右时就有很好的成绩,明显优于其他 3 种方法。

从图 4(c) 中 Space Invader 游戏的平均奖赏图可发现,UCBS-DQN 方法较其他 3 种方法有显著的提高。在经历了 500 个训练阶段后,UCBS-DQN 方法所获得的奖赏是 DQN 方法的 3 倍多、是 DRQN




Fig. 4 The average reward of different approaches in different Atari games

图 4 各方法在 Atari 游戏中的平均奖赏

方法的近 4 倍、是 PER 方法的 2 倍。而且可以看出，UCBS-DQN 方法每阶段所获得的奖赏仍然处于一个上升的趋势。这是因为 Space Invader 游戏中敌机数量已知且位置变化范围不大，UCBS-DQN 方法会以较高的概率选择那些取得高奖赏值的样本，因此，实验中 UCBS-DQN 方法所获得奖赏呈大幅上升趋势。

从图 4(d)中 Assault 游戏的平均奖赏图可以发现，UCBS-DQN 方法表现依然突出，且在 500 轮训练阶段后依然保持着上升趋势；虽然 PER 方法比 DQN 方法和 DRQN 方法好，但是，PER 方法探索性能较差，很难发现未遇到的优秀样本，导致在经历了一段时间的提升后，PER 方法中每情节所获得的奖赏难以持续提高。而由于 UCBS-DQN 方法具有较强的探索能力，可以发现更多的优秀动作，因此能保持良好的上升态势。

通过上述 4 个实验，可以得出 UCBS-DQN 方法取得效果显著时的条件：1) 在环境中存在着较难被探索到的且奖赏值较高的样本，如 Seaquest 游戏环境中上浮获取氧气；2) 环境中存在重复执行某个动作依然能获得较高奖赏的现象，如 Space Invader

游戏中击打飞机的情况。值得注意的是，UCBS-DQN 方法并非仅仅简单地改变动作的被选概率来改善效果，而是考虑了更多的信息，通过对经验池中的元组进行选择，以元组中的状态（即经过处理的图像）为输入进行网络训练，采用 ϵ -贪心方法选择动作，因此可以有效地降低陷入局部最优的可能。

损失函数的损失值是衡量算法收敛速度的一个重要标准。本文使用式(6)计算了 4 种方法在不同游戏中损失函数的损失值，如图 5 所示。

从图 5 中可以看出，每一种方法在刚开始训练时其损失值有一个上升的过程。而 UCBS-DQN 方法在短暂的上升之后，其损失值一直保持在一个非常低的状态。在 Space Invader 游戏和 Assault 游戏中，UCBS-DQN 方法的损失值甚至持续降低，这是因为 UCBS-DQN 方法有较强的探索性，使得其能快速找到最优策略。

好的方法不仅应该在训练阶段表现出上佳性能，而且能使用已经训练好的模型进行实际控制操作。为此，本文进行了实战游戏测试。在测试过程中，agent 使用训练好的模型，完全控制实战游戏，完成 50 000 步的测试，其中选择动作依然采用 ϵ -贪心

策略。在之前的测试阶段,通过选用 ϵ -贪心策略来减少过拟合的可能,而此时模型已经训练完毕,因此, ϵ 取较小数值,设为 0.01。每个模型都进行 20 次独立的测试,每次测试后获得游戏每一个情节的平均奖赏、最大值、平均奖赏的方差和每 50 000 步可以运行的游戏轮数,如表 1 所示。




Fig. 5 The loss of different approaches in different games

图 5 各方法损失值比较图

Table 1 Testing Results of Atari Games with 4 Approaches After Training

表 1 训练结束后 4 种方法在 Atari 游戏上的测试效果

Game	Approach	Average reward	Maximal reward	Variance	Rounds of game
Breakout	DQN	2.87	10.0	0.017	900.2
	UCBS-DQN	3.35	20.0	0.014	850.4
	DRQN	2.87	10.0	0.052	513.5
	PER	3.04	12.0	0.021	892.6
Seaquest	DQN	34.92	200.0	3.18	796.2
	UCBS-DQN	150.45	600.0	85.90	472.8
	DRQN	41.33	120.0	7.16	772.8
	PER	129.86	440.0	74.30	487.2
Space Invader	DQN	116.54	815.0	96.33	547.5
	UCBS-DQN	317.83	1195.0	705.57	350.8
	DRQN	72.91	500.0	2.19	957.0
	PER	162.66	940.0	169.30	475.2
Assault	DQN	197.92	1302.0	161.50	327.6
	UCBS-DQN	661.52	2142.0	3301.52	178.4
	DRQN	110.01	525.0	68.95	393.8
	PER	411.83	1058.0	1065.28	184.0

Notes: The bold values represent the maximum values in the average reward and maximal reward.

从表1中可以看出,UCBS-DQN方法在每情节所获得的平均奖赏上都有不同程度的提高。在最大值这项指标上,UCBS-DQN方法的表现依然优于其他方法。此外,UCBS-DQN方法在固定50 000步所获得平均游戏轮数最少,说明其在平均每轮游戏中存活步数最长,训练较为成功。

4 结束语

深度Q网络及其相关改进方法在Atari游戏中有着很好的表现,证明可以较好地解决一些视觉感知类问题。然而,对于战略性任务这些模型效果提高有限,主要原因在于环境中存在着需要长时间步才能表现出优秀的状态。本文提出了一种基于最大置信上界采样的UCBS-DQN方法,该方法通过对经验池进行优先级采样,可以有效地探索未知状态,提高选择优秀状态概率,在很大程度上能够避免出现探索不到延迟奖赏的问题。本文通过4个Atari 2006实验验证了UCBS-DQN方法的有效性。

然而,从实验结果中可以发现,DQN,DRQN,PER和UCBS-DQN这4种方法的稳定性都不佳。因此,在如何提高模型稳定性方面仍有工作可以继续开展,可以采用监督学习方法或经验来协助训练出模型初始参数,然后再使用强化学习来更新策略。


参 考 文 献

- [1] Sutton R S, Barto A G. Reinforcement Learning: An Introduction [M]. Cambridge, MA: MIT Press, 1998: 6–22
- [2] Liu Zhibin, Zeng Xiaoqin, Liu Huiyi, et al. A heuristic two-layer reinforcement learning algorithm based on BP neural networks [J]. Journal of Computer Research and Development, 2015, 52(3): 579–587 (in Chinese)
(刘智斌,曾晓勤,刘惠义,等. 基于BP神经网络的双层启发式强化学习方法[J]. 计算机研究与发展, 2015, 52(3): 579–587)
- [3] Kocsis L, Szepesvári C. Bandit based Monte-Carlo planning [C] //Proc of the 17th European Conf on Machine Learning. Berlin: Springer, 2006: 282–293
- [4] Chen Donghuo, Liu Quan, Zhu Fei, et al. The research on adaptive reinforcement learning technique based on convex polyhedra abstraction domain [J]. Chinese Journal of Computers, 2018, 41(1): 112–131 (in Chinese)
(陈冬火,刘全,朱斐,等. 基于凸多面体抽象域的自适应强化学习技术研究[J]. 计算机学报, 2018, 41(1): 112–131)
- [5] Russakovsky O, Deng Jia, Su Hao, et al. Imagenet large scale visual recognition challenge [J]. International Journal of Computer Vision, 2015, 115(3): 211–252
- [6] Liang Bin, Liu Quan, Xu Jin, et al. Aspect-based sentiment analysis based on multi-attention CNN [J]. Journal of Computer Research and Development, 2017, 54(8): 1724–1735 (in Chinese)
(梁斌,刘全,徐进,等. 基于多注意力卷积神经网络的特定目标情感分析[J]. 计算机研究与发展, 2017, 54(8): 1724–1735)
- [7] Xi Xuefeng, Zhou Guodong. A survey on deep learning for natural language processing [J]. Acta Automatica Sinica, 2016, 42(10): 1445–1465 (in Chinese)
(奚雪峰,周国栋. 面向自然语言处理的深度学习研究[J]. 自动化学报, 2016, 42(10): 1445–1465)
- [8] Mnih V, Kavukcuoglu K, Silver D, et al. Playing Atari with deep reinforcement learning [C] //Proc of the 26th Int Conf on Neural Information Processing Systems. Cambridge, MA: MIT Press, 2013: 85–117
- [9] Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning [J]. Nature, 2015, 518(7540): 529–533
- [10] Watkins C J C H, Dayan P. Q-learning [J]. Machine Learning, 1992, 8(3/4): 279–292
- [11] O’Neill J, Pleydellbouverie B, Dupret D, et al. Play it again: Reactivation of waking experience and memory [J]. Trends in Neurosciences, 2010, 33(5): 220–229
- [12] Liu Quan, Zhou Xiaoke, Zhu Fei, et al. Experience replay for least-squares policy iteration [J]. IEEE/CAA Journal of Automatica Sinica, 2015, 1(3): 274–281
- [13] Schaul T, Quan J, Antonoglou I, et al. Prioritized experience replay [C/OL] //Proc of Workshops at the 4th Int Conf on Learning Represents. San Diego, CA: ICLR, 2016: 1–21. [2018-03-01]. <https://arxiv.org/abs/1511.05952v4>
- [14] Auer P, Cesa-Bianchi N, Fischer P. Finite-time analysis of the multiarmed bandit problem [J]. Machine Learning, 2002, 47(2/3): 235–256
- [15] Tang Zhentao, Shao Kun, Zhao Dongbin, et al. Recent progress of deep reinforcement learning: From AlphaGo to AlphaGo Zero [J]. Control Theory and Applications, 2017, 34(12): 1529–1545 (in Chinese)
(唐振韬,邵坤,赵冬斌,等. 深度强化学习进展: 从AlphaGo到AlphaGo Zero [J]. 控制理论与应用, 2017, 34(12): 1529–1545)
- [16] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors [J]. Nature, 1986, 323(6088): 533–536
- [17] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C] //Proc of the 25th Int Conf on Neural Information Processing Systems. Cambridge, MA: MIT Press, 2012: 1097–1105
- [18] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [C/OL] //Proc of the 3rd Int Conf on Learning Representations. San Diego, CA: ICLR, 2015: 1–14. [2018-03-01]. <https://arxiv.org/abs/1409.1556v6>


- [19] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition [C] //Proc of the IEEE Conf on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2016: 770-778
- [20] Connor J T, Martin R D, Atlas L E. Recurrent neural networks and robust time series prediction [J]. IEEE Trans on Neural Networks, 2002, 5(2): 240-254
- [21] Chung Junyong, Gulcehre C, Cho Kyung Hyun, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling [C/OL] //Proc of the 27th Int Conf on Neural Information Processing Systems. Cambridge, MA: MIT Press, 2014: 1-9. [2018-03-01]. <https://arxiv.org/abs/1412.3555>
- [22] Liu Quan, Zhai Jianwei, Zhong Shan. A deep recurrent Q-network based on visual attention mechanism [J]. Chinese Journal of Computers, 2017, 40(6): 1353-1366 (in Chinese) (刘全, 翟建伟, 钟珊, 等. 一种基于视觉注意力机制的深度循环Q网络模型[J]. 计算机学报, 2017, 40(6): 1353-1366)
- [23] Van Hasselt H, Guez A, Silver D. Deep reinforcement learning with double Q-learning [C] //Proc of the 30rd AAAI Conf on Artificial Intelligence. Menlo Park, CA: AAAI, 2016: 2094-2100
- [24] Van Hasselt H. Double Q-learning [C] //Proc of the 23rd Int Conf on Neural Information Processing Systems. Cambridge, MA: MIT Press, 2010: 2613-2621
- [25] Lakshminarayanan A S, Sharma S, Ravindran B. Dynamic frame skip deep Q network [C/OL] //Proc of the 25th Int Joint Conf on Artificial Intelligence. New York: IJCAI, 2016: 1-7. [2018-03-01]. <https://arxiv.org/abs/1605.05365v2>
- [26] Wang Ziyu, Schaul T, Hessel M, et al. Dueling network architectures for deep reinforcement learning [C] //Proc of the 33rd Int Conf on Machine Learning. New York: The Journal of Machine Learning Research, 2016: 1995-2003
- [27] Narasimhan K, Kulkarni T, Barzilay R. Language understanding for text-based games using deep reinforcement learning [C] //Proc of Workshops at the 2015 Conf on

Empirical Methods on Natural Language Processing. Stroudsburg, PA: ACL, 2015: 1-15

- [28] Cheng Jianpeng, Dong Li, Lapata M. Long short-term memory-networks for machine reading [C] //Proc of Empirical Methods on Natural Language Processing. Stroudsburg, PA: ACL, 2016: 1-11
- [29] Hausknecht M, Stone P. Deep recurrent Q-learning for partially observable MDPs [C] //Proc of the 29th AAAI Conf on Artificial Intelligence. Menlo Park, CA: AAAI, 2015: 29-37



Zhu Fei, born in 1978. PhD and associate professor. Member of CCF. His main research interests include reinforcement learning, text mining and bioinformatics.



Wu Wen, born in 1994. Postgraduate of Soochow University. His main research interests include deep reinforcement learning and intelligence information processing (20164227051@stu.suda.edu.cn).



Liu Quan, born in 1969. PhD and professor. Member of CCF. His main research interests include reinforcement learning, and automated reasoning (quanliu@suda.edu.cn).



Fu Yuchen, born in 1968. PhD and professor. Member of CCF. His main research interests include reinforcement learning, intelligence information processing and deep Web (yuchenfu@cslg.edu.cn).