强化学习2022
第7节

涉及知识点：
深度强化学习、深度Q网络

深度强化学习价值方法

张伟楠 – 上海交通大学

课程回顾：基于表格的强化学习

基于模型的动态规划

- 值迭代 $V(s) = R(s) + \max_{a \in A} \gamma \sum_{s' \in S} P_{sa}(s') V(s')$
- 策略迭代 $\pi(s) = \arg\max_{a \in A} \sum_{s' \in S} P_{sa}(s') V(s')$

无模型的强化学习

- 在线策略蒙特卡洛 $V(s_t) \leftarrow V(s_t) + \alpha(G_t - V(s_t))$
- 在线策略时序差分 $V(s_t) \leftarrow V(s_t) + \alpha\big(r_{t+1} + \gamma V(s_{t+1}) - V(s_t)\big)$
- 在线策略时序差分 SARSA学习

  $Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha(r_{t+1} + \gamma Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t))$
- 离线策略时序差分 Q-学习

  $Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha(r_{t+1} + \gamma \max_{a'} Q(s_{t+1}, a') - Q(s_t, a_t))$

课程回顾：价值和策略的近似逼近方法

- 价值和策略的近似逼近方法是强化学习技术从‘玩具’走向‘现实’的第一步，是深度强化学习的基础设置
- 参数化的价值函数（$V_\phi(s), Q_\phi(s,a)$）和策略$\pi_\theta(a|s)$
- 通过链式法则，价值函数的参数可以被直接学习

$$\phi \leftarrow \phi + \alpha\left(\underbrace{r_{t+1} + \gamma V_\phi(s_{t+1})}_{\text{无梯度}} - V_\phi(s)\right)\frac{\partial V_\phi(s_t)}{\partial \phi}$$

- 通过likelihood-ratio方法，可以用advantage对策略的参数进行学习

$$\frac{\partial J(\theta)}{\partial \theta} = \mathbb{E}_{\pi_\theta}\left[\frac{\partial \log \pi_\theta(a|s)}{\partial \theta}\underbrace{Q^{\pi_\theta}(s,a)}_{\text{无梯度}}\right]$$

- Actor-critic框架同时学习了价值函数和策略，通过价值函数的Q（或Advantage）估计，以策略梯度的方式更新策略参数

课程大纲

强化学习基础部分

1. 强化学习、探索与利用
2. MDP和动态规划
3. 值函数估计
4. 无模型控制方法
5. 规划与学习
6. 参数化的值函数和策略
7. 深度强化学习价值方法
8. 深度强化学习策略方法

强化学习前沿部分

9. 基于模型的深度强化学习
10. 模仿学习
11. 离线强化学习
12. 参数化动作空间
13. 目标导向的强化学习
14. 多智能体强化学习
15. 强化学习大模型
16. 技术交流与回顾

深度强化学习

张伟楠 – 上海交通大学

价值和策略近似

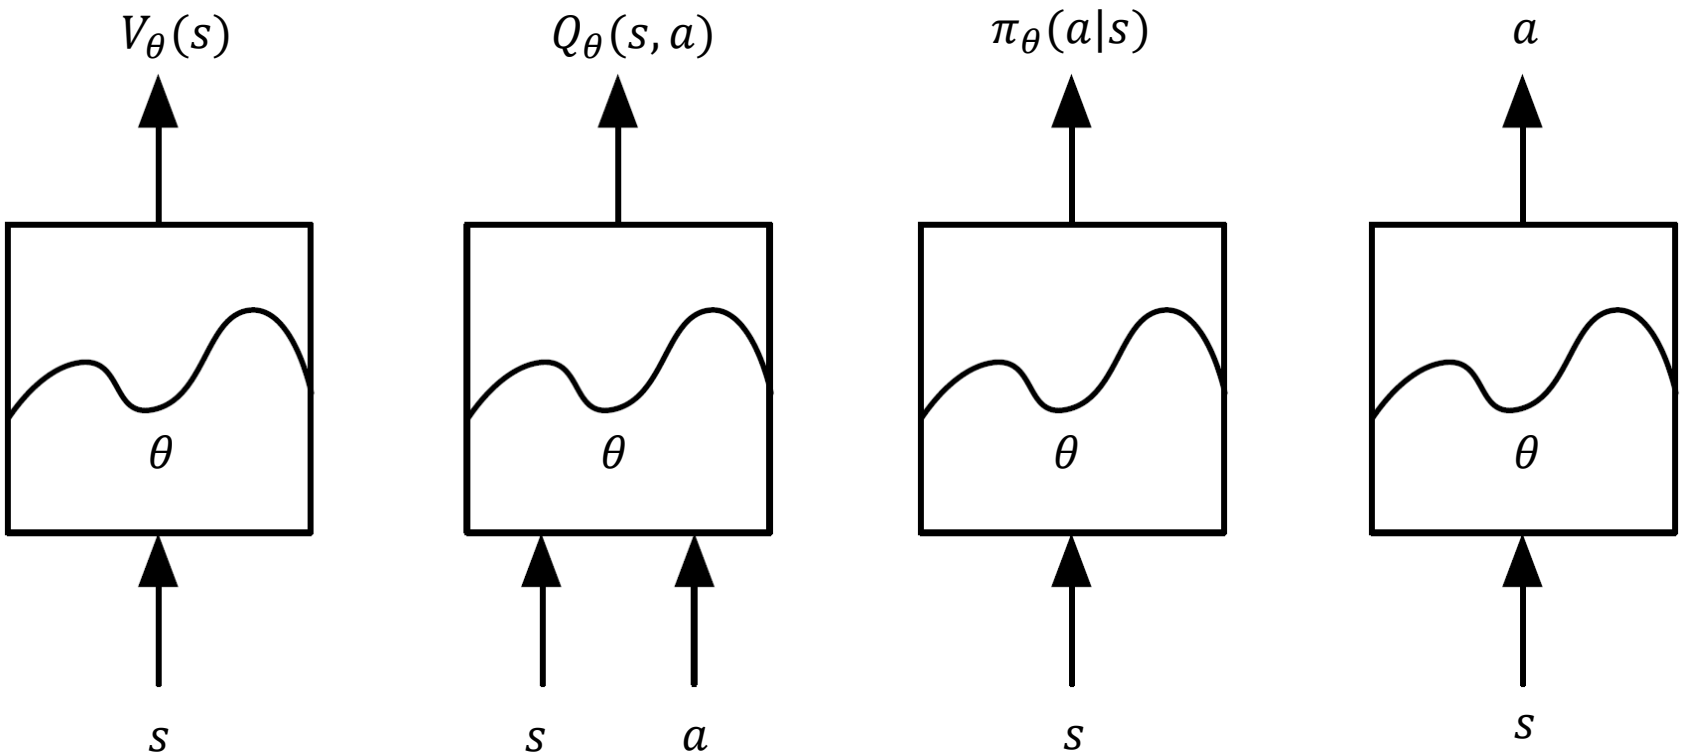

状态值函数和状态动作值函数近似　　随机策略近似　　确定性策略近似

- 假如我们直接使用深度神经网络建立这些近似函数呢?

端到端强化学习

标准（传统）
计算机视觉

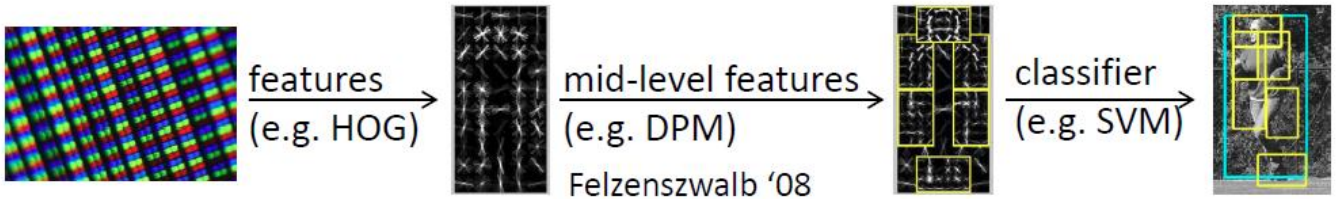

深度学习

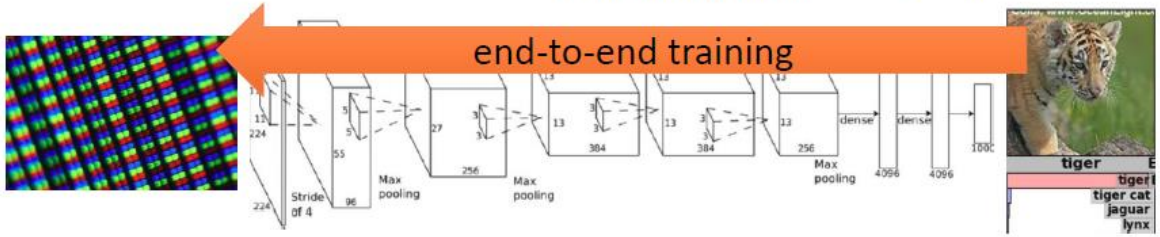

标准（传统）
强化学习

深度强化学习

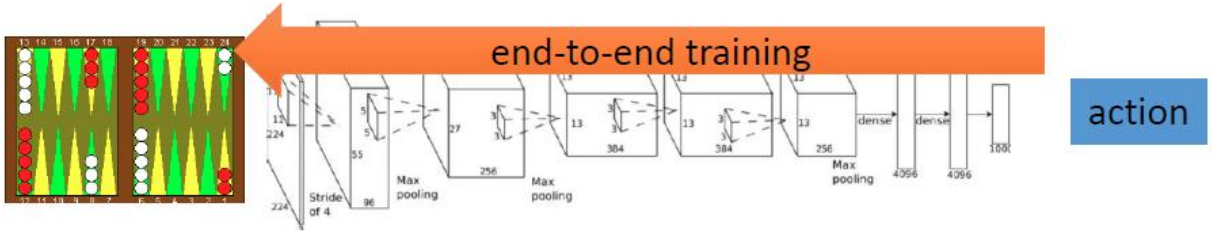

深度强化学习使强化学习算法能够以端到端的方式解决复杂问题

Slide from Sergey Levine. http://rail.eecs.berkeley.edu/deeprlcourse/static/slides/lec-1.pdf

深度强化学习

深度强化学习

- 利用深度神经网络进行价值函数和策略近似
- 从而使强化学习算法能够以端到端的方式解决复杂问题

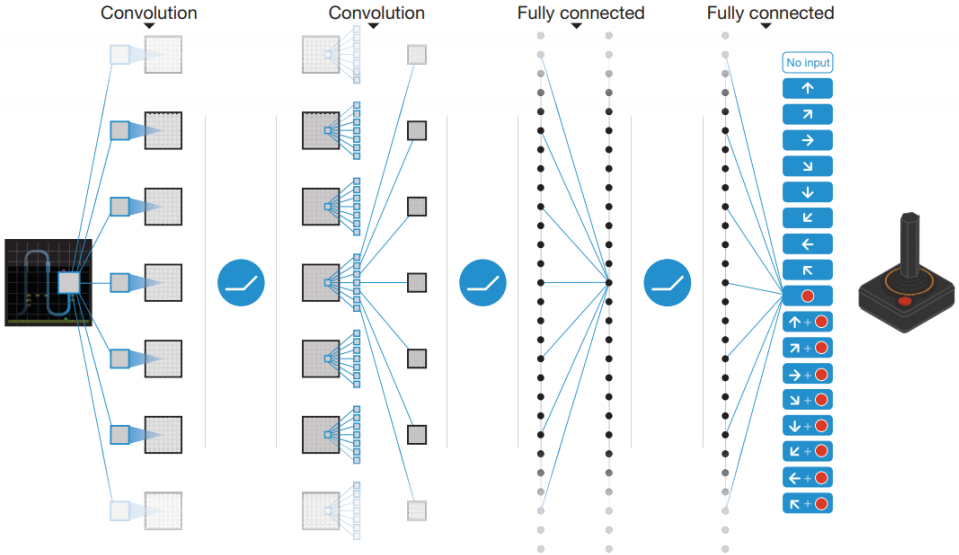

Volodymyr Mnih, Koray Kavukcuoglu, David Silver et al.
Playing Atari with Deep Reinforcement Learning. NIPS 2013 workshop.

深度强化学习带来的关键变化

- 假如将深度学习（DL）和强化学习（RL）结合在一起会发生什么？
  - 价值函数和策略现在变成了深度神经网络
  - 相当高维的参数空间
  - 难以稳定地训练
  - 容易过拟合
  - 需要大量的数据
  - 需要高性能计算
  - CPU（用于收集经验数据）和GPU（用于训练神经网络）之间的平衡
  - …

这些新的问题促进着深度强化学习算法的创新

深度强化学习的分类

- 基于价值的方法
  - 深度Q网络及其扩展
- 基于随机策略的方法
  - 使用神经网络的策略梯度，自然策略梯度，信任区域策略优化（TRPO），近端策略优化（PPO），A3C
- 基于确定性策略的方法
  - 确定性策略梯度（DPG），DDPG

深度Q网络

张伟楠 – 上海交通大学

目录

Contents

01 深度Q网络（DQN）

02 Double DQN

03 Dueling DQN

01

深度Q网络（DQN）

Q 学习回顾

- 不直接更新策略
- 基于值的方法
- Q 学习算法学习一个由 θ 作为参数的函数 $Q_\theta(s,a)$

  - Target值 $y_{\mathrm{t}} = r_t + \gamma \max_{a'} Q_\theta(s_{t+1}, a')$

  - 更新方程 $Q_\theta(s_t, a_t) \leftarrow Q_\theta(s_t, a_t) + \alpha(r_t + \gamma \max_{a'} Q_\theta(s_{t+1}, a') - Q_\theta(s_t, a_t))$

  - 优化目标

$$\theta^\star \leftarrow \arg\min_\theta \frac{1}{2} \sum_{(s_t,a_t)\in D} (Q_\theta(s_t, a_t) - (r + \gamma \max_{a'} \underbrace{Q_\theta(s_{t+1}, a')}_{\text{此处无梯度}}))^2$$

深度Q网络（DQN）

直观想法

- 使用神经网络来逼近上述 $Q_\theta(s,a)$
  - 算法不稳定
    - 连续采样得到的 $\{(s_t,a_t,s_{t+1},r_t)\}$ 不满足独立分布。
    - $\{(s_t,a_t,s_{t+1},r_t)\}$ 为状态-动作-下一状态-回报输入。
    - $Q_\theta(s,a)$ 的频繁更新。

解决办法

- 经验回放
- 使用双网络结构：评估网络（evaluation network）和目标网络（target network）

Mnih, Kavukcuoglu, Silver et al. Human-Level Control Through Deep Reinforcement Learning. Nature 2015.

经验回放

- 经验回放
  - 存储训练过程中的每一步 $e_t = (s_t, a_t, s_{t+1}, r_t)$ 于数据库 D 中，采样时服从均匀分布。

优先经验回放

- 衡量标准
  - 以 Q 函数的值与 Target 值的差异来衡量学习的价值，即

$$p_t = |r_t + \gamma \max_{a'} Q_\theta(s_{t+1}, a') - Q_\theta(s_t, a_t)|$$

  - 为了使各样本都有机会被采样，存储 $e_t = (s_t, a_t, s_{t+1}, r_t, p_t + \epsilon)$。
- 选中的概率
  - 样本 e_t 被选中的概率为 $P(t) = \frac{p_t^\alpha}{\sum_k p_k^\alpha}$。
- 重要性采样（Importance Sampling）
  - 权重为 $\omega_t = \frac{(N \times P(t))^{-\beta}}{\max_i \omega_i}$

Schaul et al. Prioritized Experience Replay. ICLR 2016.

经验回放

Algorithm 1 Double DQN with proportional prioritization

Input: minibatch k, step-size η, replay period K and size N, exponents α and β, budget T.
Initialize replay memory $\mathcal{H} = \emptyset$, $\Delta = 0$, $p_1 = 1$
Observe S_0 and choose $A_0 \sim \pi_\theta(S_0)$
for $t = 1$ **to** T **do**
  Observe S_t, R_t, γ_t
  Store transition $(S_{t-1}, A_{t-1}, R_t, \gamma_t, S_t)$ in $\mathcal{H}$ with maximal priority $p_t = \max_{i<t} p_i$
  if $t \equiv 0 \mod K$ **then**
    for $j = 1$ **to** k **do**
      Sample transition $j \sim P(j) = p_j^\alpha / \sum_i p_i^\alpha$
      Compute importance-sampling weight $w_j = (N \cdot P(j))^{-\beta} / \max_i w_i$
      Compute TD-error $\delta_j = R_j + \gamma_j Q_{\text{target}}(S_j, \arg\max_a Q(S_j, a)) - Q(S_{j-1}, A_{j-1})$
      Update transition priority $p_j \leftarrow |\delta_j|$
      Accumulate weight-change $\Delta \leftarrow \Delta + w_j \cdot \delta_j \cdot \nabla_\theta Q(S_{j-1}, A_{j-1})$
    end for
    Update weights $\theta \leftarrow \theta + \eta \cdot \Delta$, reset $\Delta = 0$
    From time to time copy weights into target network $\theta_{\text{target}} \leftarrow \theta$
  end if
  Choose action $A_t \sim \pi_\theta(S_t)$
end for

Schaul et al. Prioritized Experience Replay. ICLR 2016.

目标网络

- 目标网络 $Q_{\theta^-}(s,a)$
  - 使用较旧的参数，记为 θ^-，每隔 C 步和训练网络的参数同步一次。
  - 第i次迭代的损失函数为

$$L_i(\theta_i) = \mathbb{E}_{s_t,a_t,s_{t+1},r_t,p_t\sim D}[\frac{1}{2}\omega_t(\underbrace{r_t + \gamma \max_{a'} Q_{\theta_i^-}(s_{t+1},a')}_{target} - Q_{\theta_i}(s_t,a_t))^2]$$

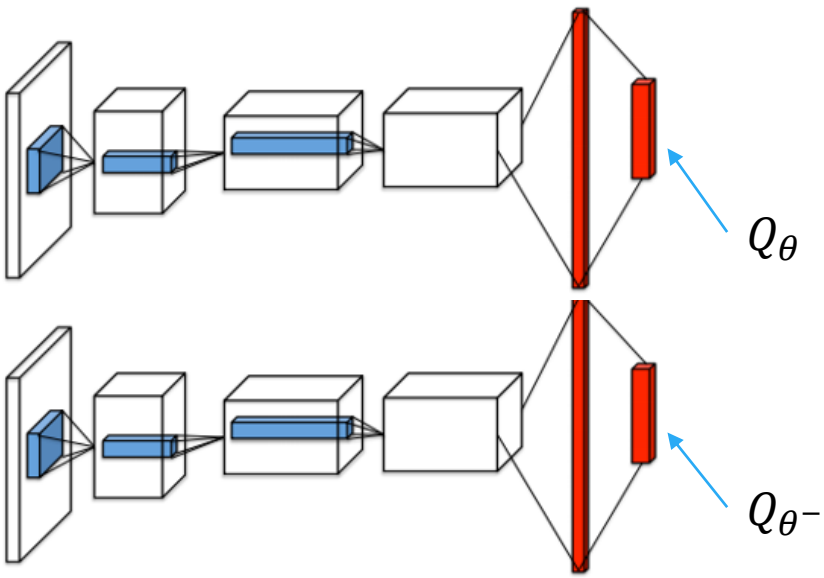

Mnih, Kavukcuoglu, Silver et al. Human-Level Control Through Deep Reinforcement Learning. Nature 2015.

算法流程

1. 收集数据：使用 $\epsilon-\text{greedy}$ 策略进行探索，将得到的状态动作组 (s_t, a_t, s_{t+1}, r_t) 放入经验池（replay-buffer）

2. 采样：从数据库中采样 k 个动作状态组

3. 更新网络
   - 用采样得到的数据计算 $Loss$。
   - 更新 Q 函数网络 θ。
   - 每 C 次迭代（更新Q函数网络）更新一次目标网络 θ^-。

Mnih, Kavukcuoglu, Silver et al. Human-Level Control Through Deep Reinforcement Learning. Nature 2015.

在 Atari 环境中的实验结果

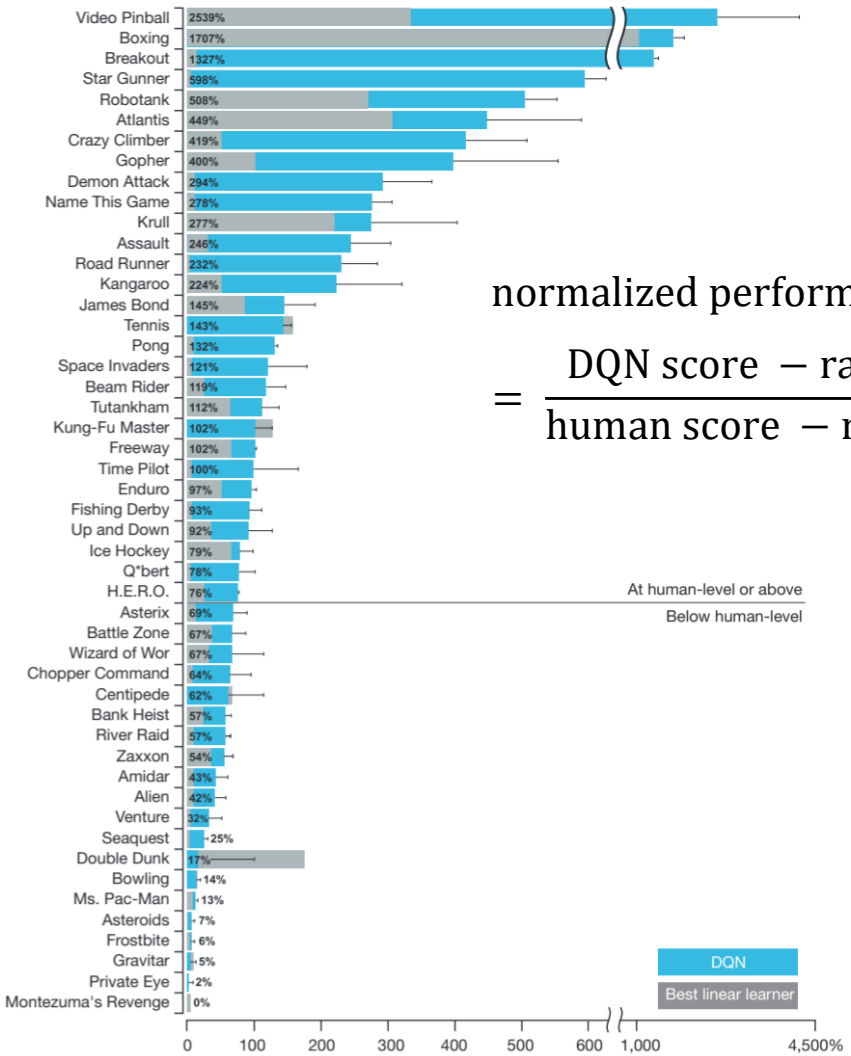

$$\text{normalized performance} = \frac{\text{DQN score} - \text{random play score}}{\text{human score} - \text{random play score}}$$

The performance of DQN is normalized with respect to a professional human games tester (that is, 100% level)

Mnih, Kavukcuoglu, Silver et al. Human-Level Control Through Deep Reinforcement Learning. Nature 2015.

02
Double DQN

Q-learning中的过估计

- Q函数的过高估计
  - Target值 $\mathrm{y_t} = r_t + \gamma \max_{a'} Q_\theta(s_{t+1}, a')$

max 操作使得 Q 函数的值越来越大，甚至高于真实值

- 过高估计的原因
  - 假设有随机变量 X_1, X_2，有 $\mathbb{E}[\max(X_1, X_2)] \geq \max(\mathbb{E}[X_1], \mathbb{E}[X_2])$

$$
\begin{aligned}
\max_{a' \in A} Q_{\theta'}(s_{t+1}, a') &= Q_{\theta'}(s_{t+1}, \arg\max_{a'} Q_{\theta'}(s_{t+1}, a')) \\
&= \mathbb{E}[R | s_{t+1}, \arg\max_{a'} Q_{\theta'}(s_{t+1}, a'), \theta'] \\
&\geq \max(\mathbb{E}[R | s_{t+1}, a_1, \theta'], \mathbb{E}[R | s_{t+1}, a_2, \theta'], \cdots), a_i \in A
\end{aligned}
$$

Q 函数的值被视作在状态 s'，动作 a' 下的回报期望值

我们真正想要得到的最大价值

Hado Hasselt et al. Deep Reinforcement Learning with Double Q-Learning. AAAI 2016.
Hado Hasselt. Double Q-learning. NIPS 2010.

Q-learning中的过估计

- Q函数的过高估计程度随着候选行动数量增大变得更严重

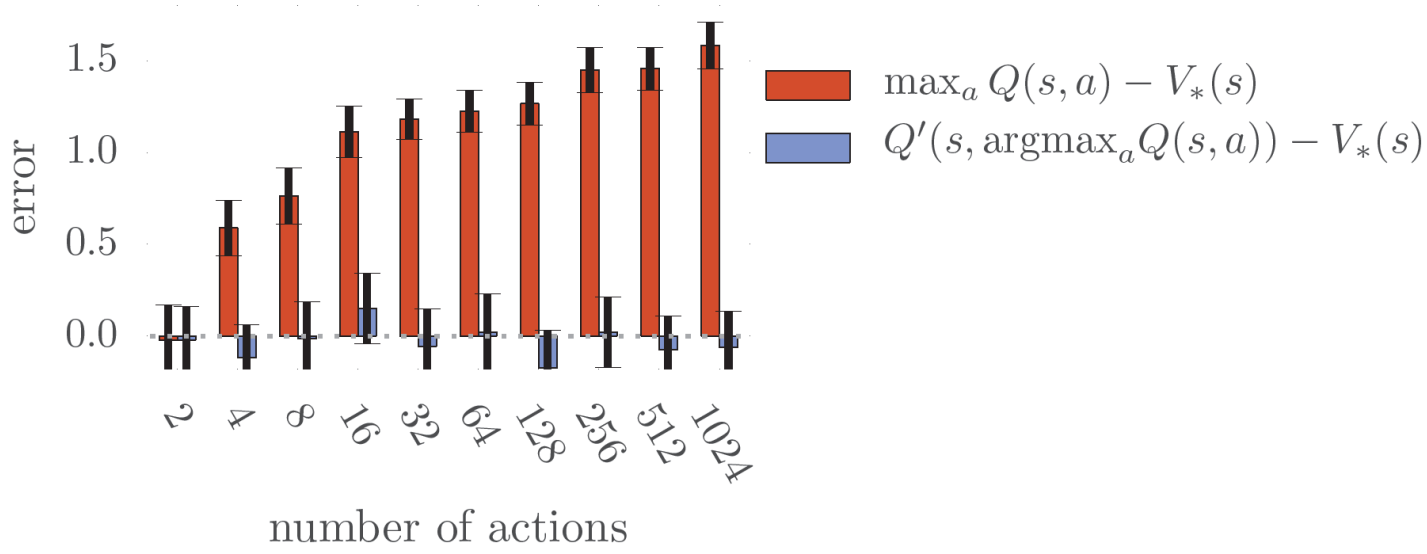

- 其中$Q_t(s,a) - V_*(s)$设为在[-1,1]区间均匀分布
- Q'函数是另一组独立训练的价值函数

Hado Hasselt et al. Deep Reinforcement Learning with Double Q-Learning. AAAI 2016.
Hado Hasselt. Double Q-learning. NIPS 2010.

Q-learning中过估计的例子

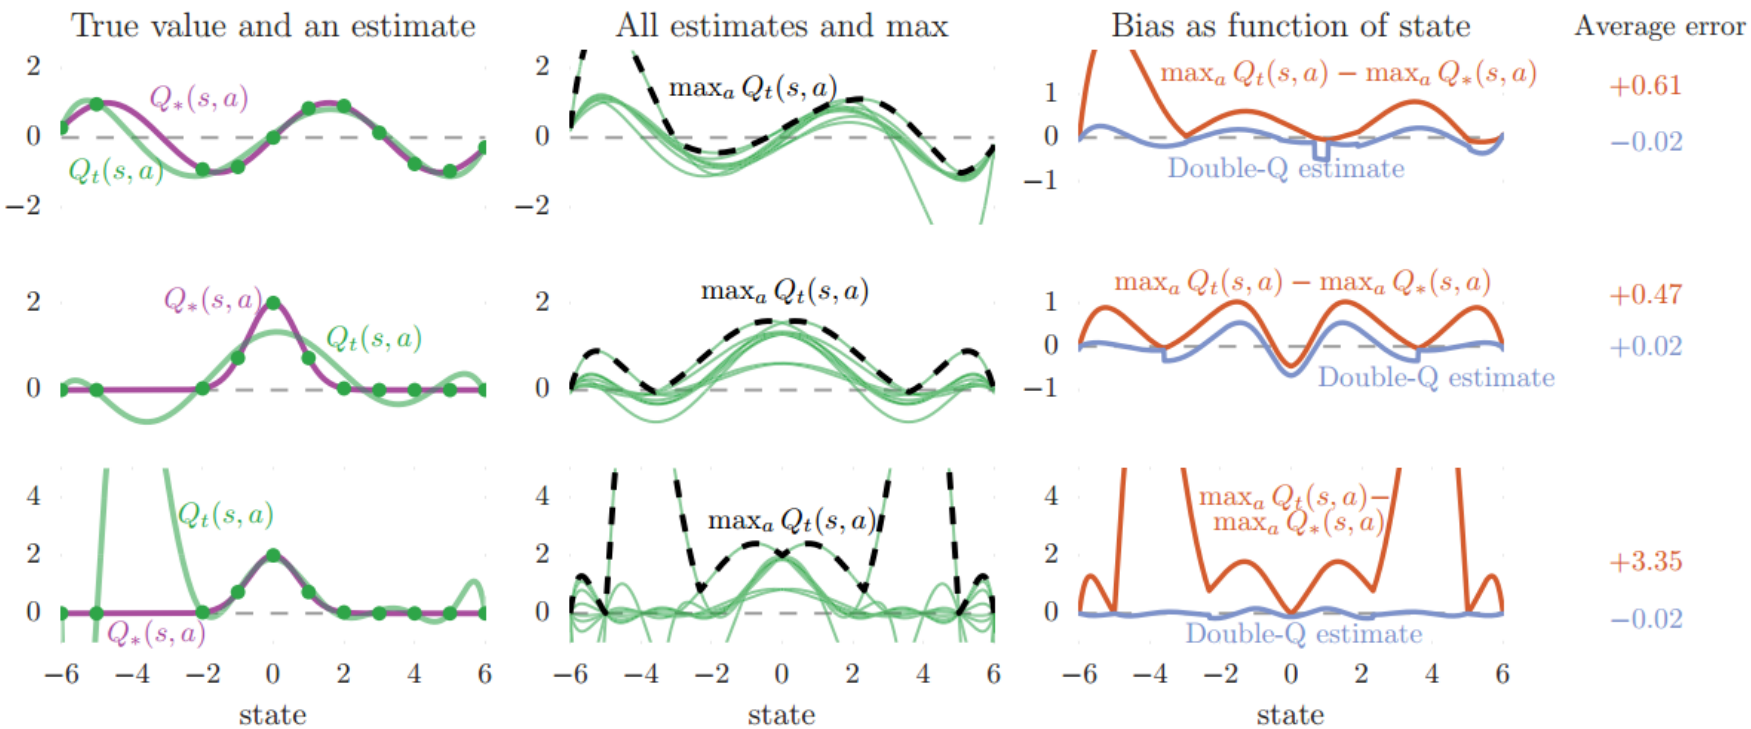

- 设置：x轴为状态，10个候选行动；紫线是真实价值函数，绿点是训练数据点，绿线是拟合的价值函数
- 中间列展示10个行动的$Q_t(s,a)$估计，在取max后，与真实$Q_*(s,a)$差距太大

Hado Hasselt et al. Deep Reinforcement Learning with Double Q-Learning. AAAI 2016.

Double DQN

- 使用不同的网络来估值和决策

DQN $y_t = r_t + \gamma Q_\theta(s_{t+1}, \arg\max_{a'} Q_\theta(s_{t+1}, a'))$

Double DQN $y_t = r_t + \gamma \boxed{Q_{\theta'}}(s_{t+1}, \arg\max_{a'} Q_\theta(s_{t+1}, a'))$

Hado Hasselt et al. Deep Reinforcement Learning with Double Q-Learning. AAAI 2016.

在 Atari 环境中的实验结果

- 价值估计误差

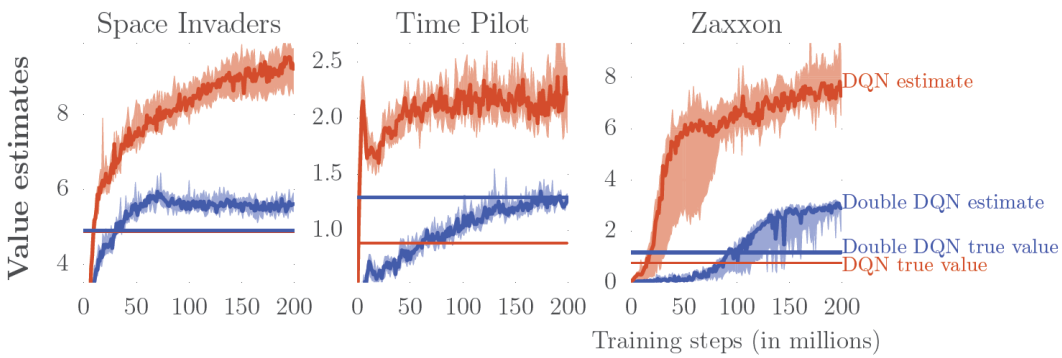

- Atari Performance

	no ops		human starts		
	DQN	DDQN	DQN	DDQN	DDQN (tuned)
Median	93%	**115%**	47%	88%	**117%**
Mean	241%	**330%**	122%	273%	**475%**

normalized performance

$$= \frac{\text{DQN score} - \text{random play score}}{\text{human score} - \text{random play score}}$$

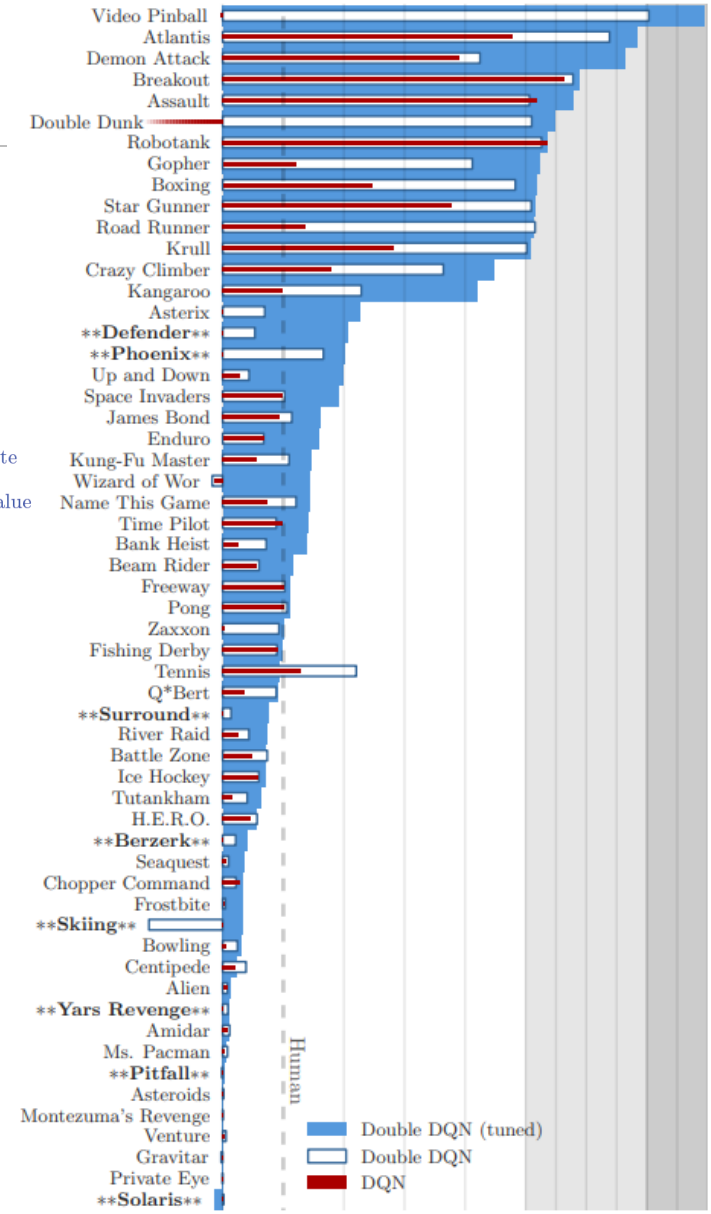

Hado Hasselt et al. Deep Reinforcement Learning with Double Q-Learning. AAAI 2016.

04

Dueling DQN

Dueling DQN

假设动作值函数服从某个分布：

$$Q(s,a) \sim \mathcal{N}(\mu,\sigma)$$

显然：$V(s) = \mathbb{E}[Q(s,a)] = \mu$

同样有：$Q(s,a) = \mu + \boxed{\varepsilon(s,a)}$

偏移量

问题

如何描述 $\varepsilon(s,a)$? → $\varepsilon(s,a) = Q(s,a) - V(s)$ → 也称为Advantage函数

Ziyu Wang et al. Dueling network architectures for deep reinforcement learning. ICML 2016.

Dueling DQN

Advantage 函数

$$A^{\pi}(s,a) = Q^{\pi}(s,a) - V^{\pi}(s)$$

$$Q^{\pi}(s,a) = \mathbb{E}[R_t | s_t = s, a_t = a, \pi]$$

$$V^{\pi}(s) = \mathbb{E}_{a \sim \pi(s)}[Q^{\pi}(s,a)]$$

不同的Advantage聚合形式

$$Q(s,a;\theta,\alpha,\beta) = V(s;\theta,\beta) + \boxed{(A(s,a;\theta,\alpha) - \max_{a' \in |A|} A(s,a';\theta,\alpha))}$$

$$Q(s,a;\theta,\alpha,\beta) = V(s;\theta,\beta) + \boxed{(A(s,a;\theta,\alpha) - \frac{1}{|A|}\sum_{a'} A(s,a';\theta,\alpha))}$$

Ziyu Wang et al. Dueling network architectures for deep reinforcement learning. ICML 2016.

网络结构

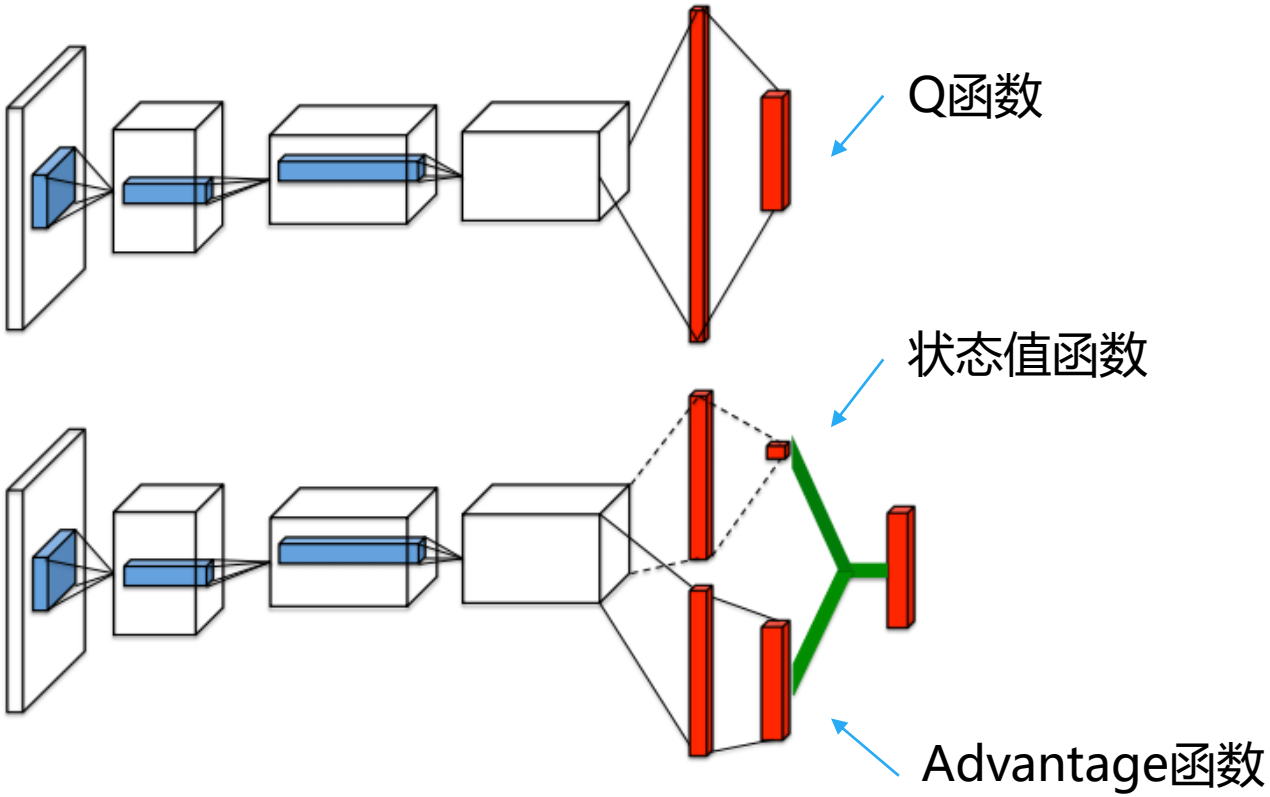

Ziyu Wang et al. Dueling network architectures for deep reinforcement learning. ICML 2016.

优点

- 处理与动作关联较小的状态
- 状态值函数的学习较为有效：一个状态值函数对应多个Advantage函数

显著区域
(saliency maps)

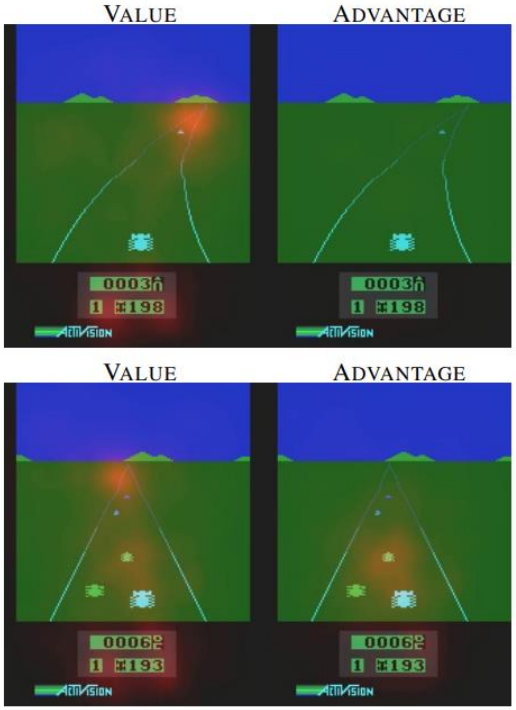

可以在不考虑动作的影响下判断出该状态的好坏。

可以强调动作的重要性：advantage学会只在agent面前有车的时候会加强注意力

Ziyu Wang et al. Dueling network architectures for deep reinforcement learning. ICML 2016.

探索任务：走廊环境

- 走廊环境
  - *为起点状态
  - 行动：上、下、左、右、不动
  - 左下角有小的正向奖励
  - 右上角有大的正向奖励
- Q函数评估均方误差

CORRIDOR ENVIRONMENT

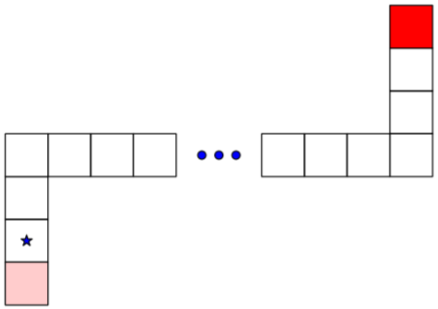

更多的行动是‘不动’

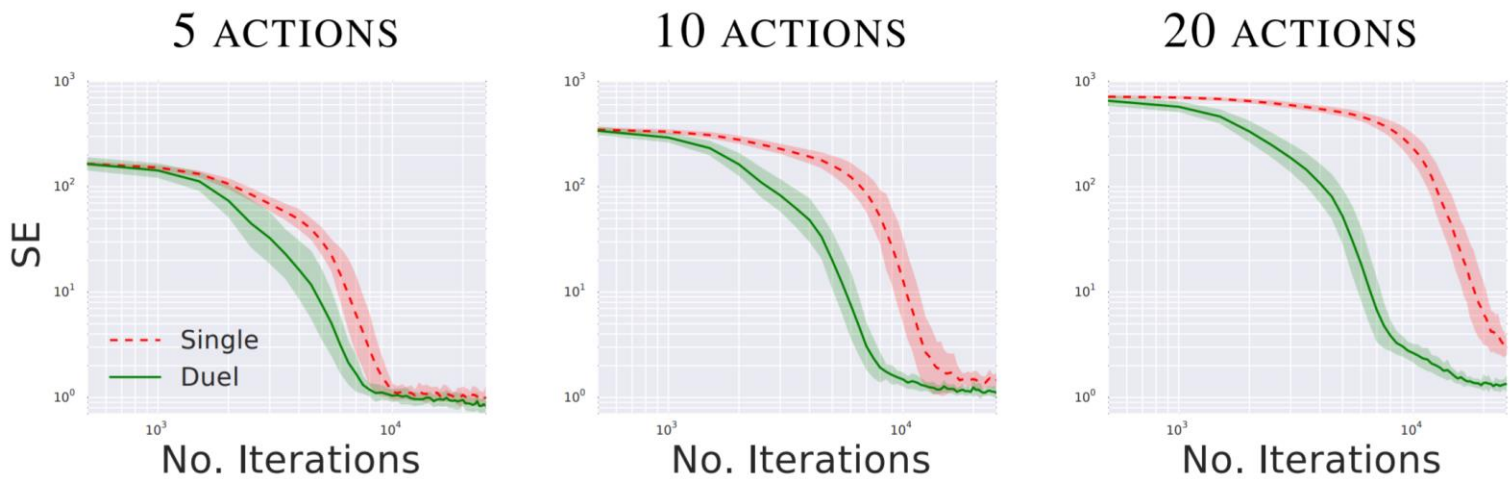

Ziyu Wang et al. Dueling network architectures for deep reinforcement learning. ICML 2016.

在 Atari 环境中的实验结果I

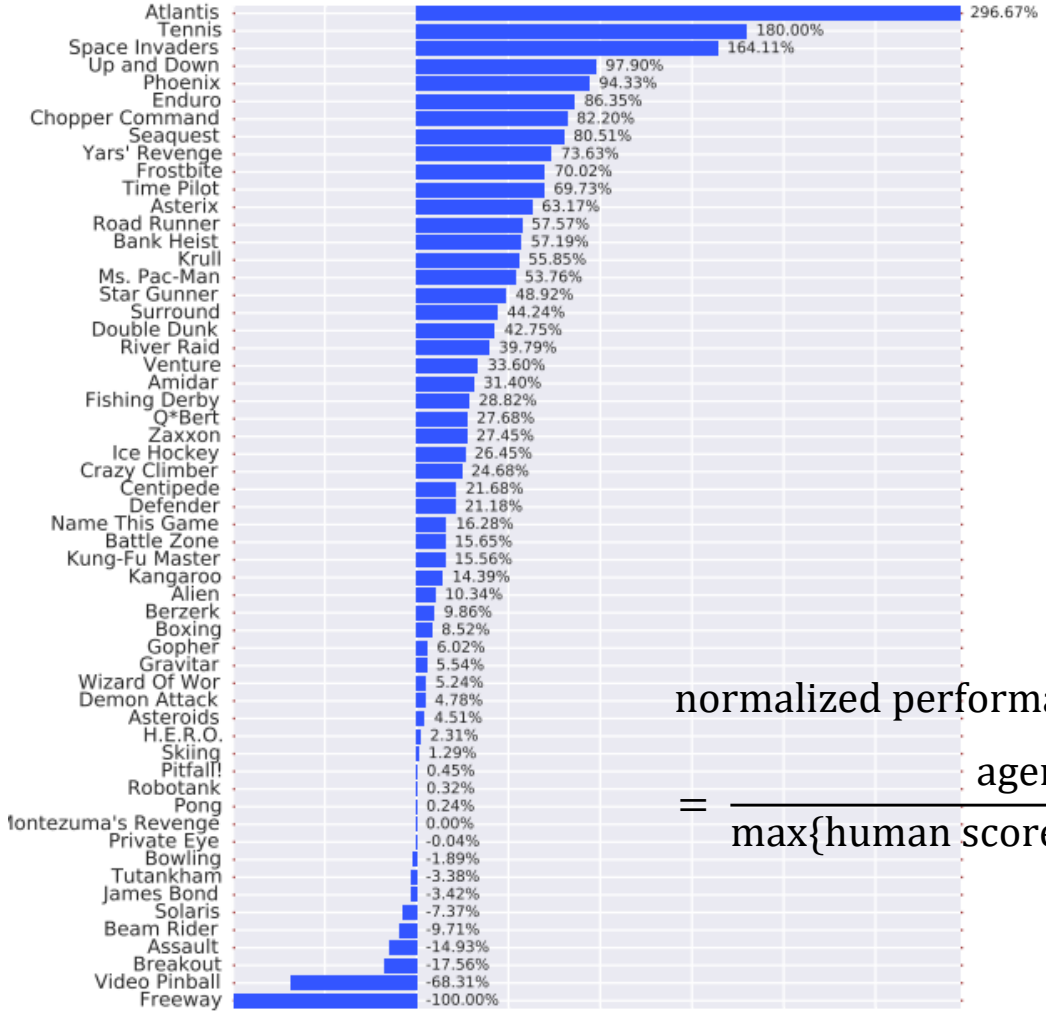

Dueling DQN与DQN对比

$$\text{normalized performance} = \frac{\text{agent score} - \text{baseline score}}{\max\{\text{human score}, \text{baseline score}\} - \text{random play score}}$$

Ziyu Wang et al. Dueling network architectures for deep reinforcement learning. ICML 2016.

在 Atari 环境中的实验结果II

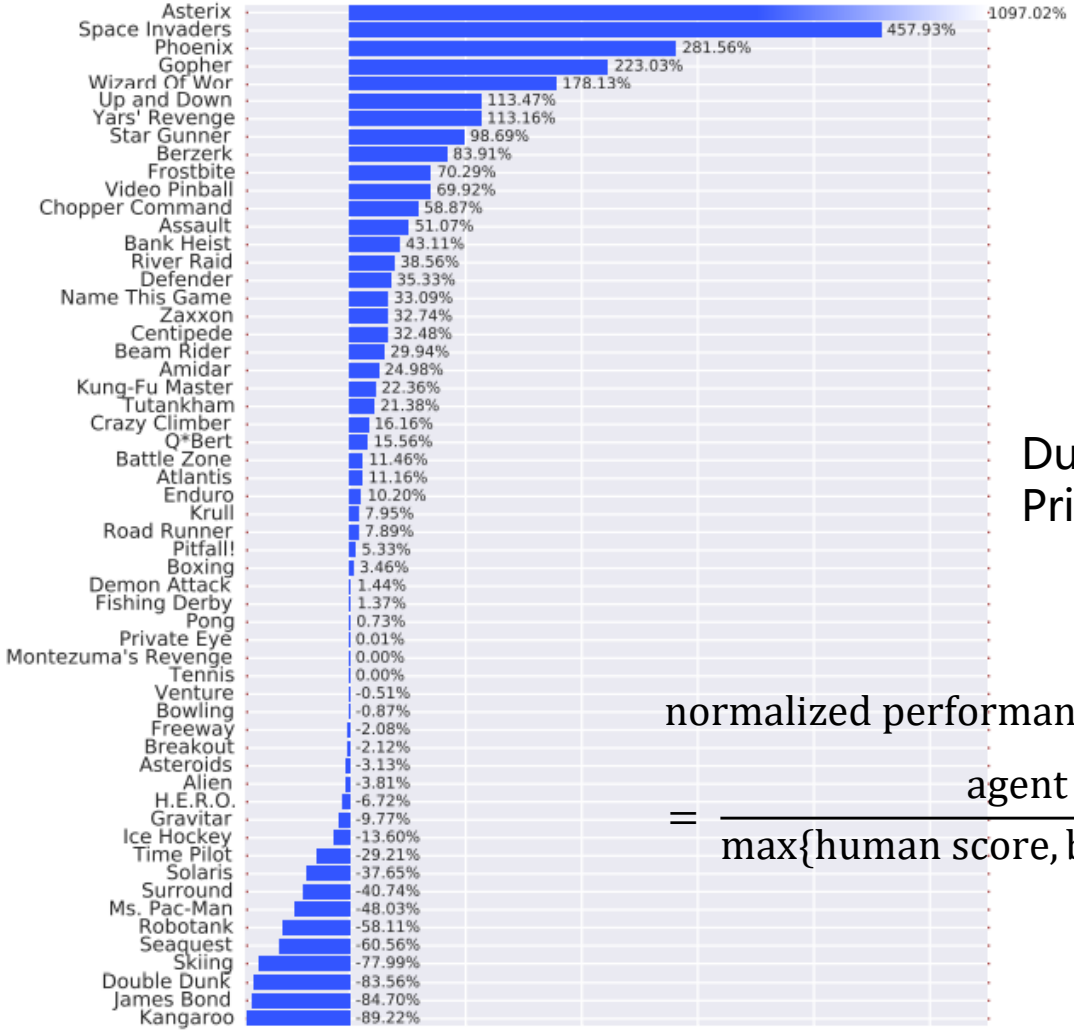

Dueling DQN与
Prioritized Double DQN对比

$$\text{normalized performance} = \frac{\text{agent score} - \text{baseline score}}{\max\{\text{human score}, \text{baseline score}\} - \text{random play score}}$$

Ziyu Wang et al. Dueling network architectures for deep reinforcement learning. ICML 2016.

复习之前的深度强化学习算法

- DQN：一次输入多个行动Q值输出、目标网络、随机采样经验

$$y_t = r_t + \gamma Q_{\theta'}(s_{t+1}, \arg\max_{a'} Q_{\theta'}(s_{t+1}, a'))$$

“Human-Level Control Through Deep Reinforcement Learning”, Mnih, Kavukcuoglu, Silver et al. Nature 2015.

- Double DQN：解耦合行动选择和价值估计、解决DQN过高估计问题

$$y_t = r_t + \gamma Q_{\theta'}(s_{t+1}, \arg\max_{a'} Q_{\theta}(s_{t+1}, a'))$$

“Double Reinforcement Learning with Double Q-Learning”, van Hasselt et al. AAAI 2016.

- Dueling DQN：精细捕捉价值和行动的细微关联、多种advantage函数建模

$$Q(s, a; \theta, \alpha, \beta) = V(s; \theta, \beta) + A(s, a; \theta, \alpha) - \frac{1}{|A|}\sum_{a'} A(s, a'; \theta, \alpha)$$

Ziyu Wang et al. Dueling network architectures for deep reinforcement learning. ICML 2016.

Rainbow: 结合众多Value-based DRL方法

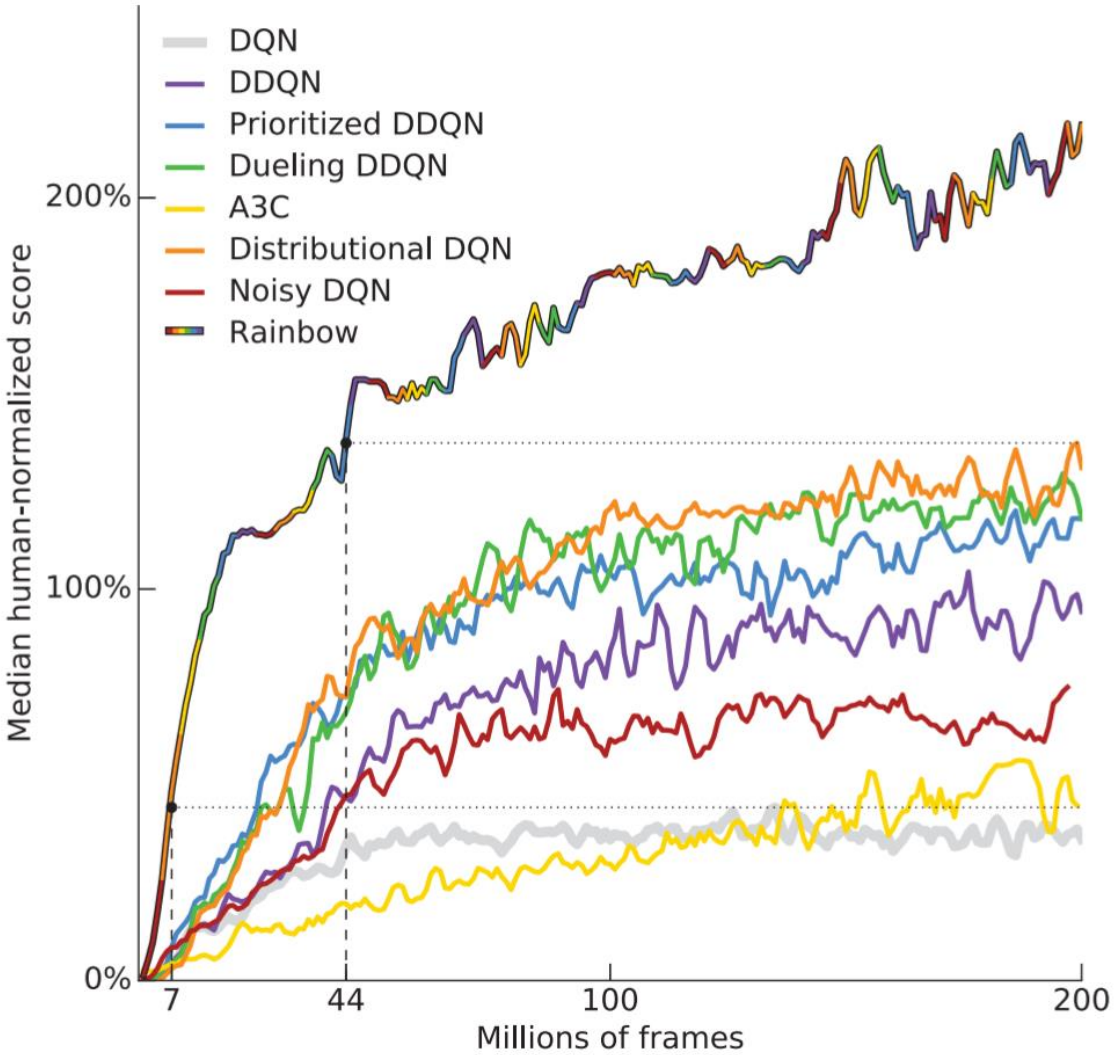

Hessel et al. Rainbow: Combining Improvements in Deep Reinforcement Learning. AAAI 2018.

深度强化学习总结

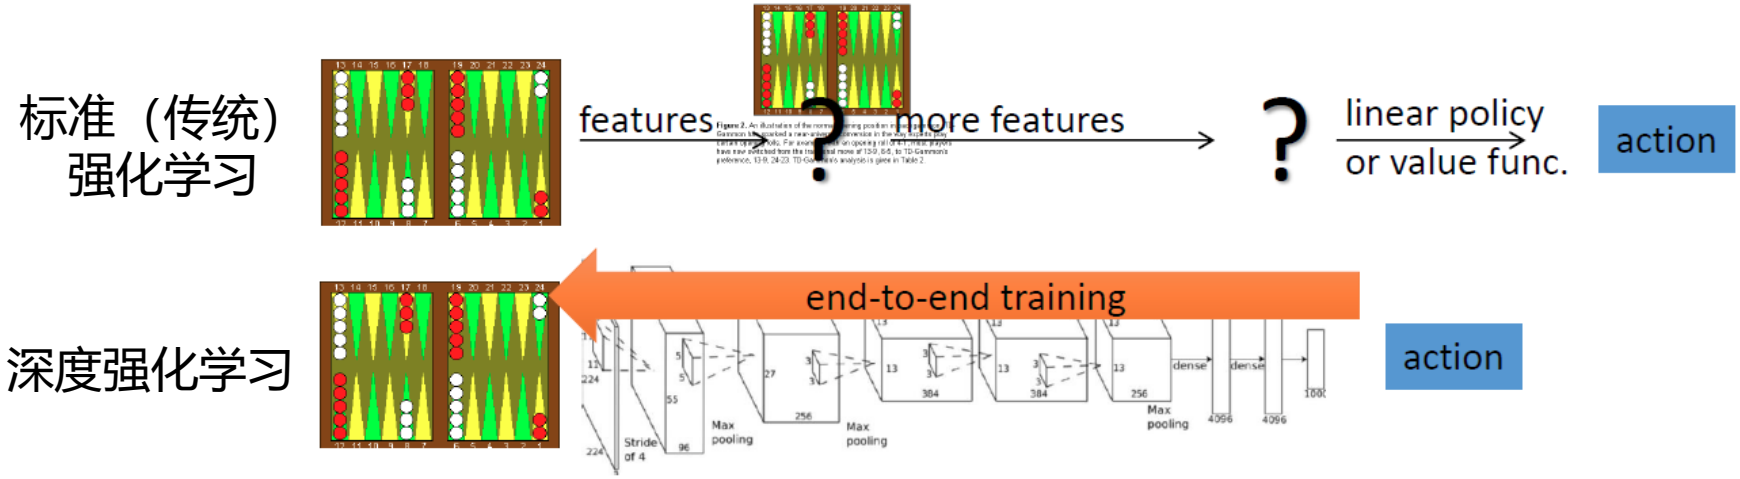

- 直面理解：深度学习+强化学习
- 深度强化学习使强化学习算法能够以端到端的方式解决复杂问题
- 真正让强化学习有能力完成实际决策任务
- 比强化学习和深度学习各自都更加难以驯化
- 基于价值函数的深度强化学习
  - DQN：一次输入多个行动Q值输出、目标网络、随机采样经验
  - Double DQN：解耦合行动选择和价值估计、解决DQN过高估计问题
  - Dueling DQN：精细捕捉价值和行动的细微关联、多种advantage函数建模

THANK YOU