

强化学习2022

第6节

涉及知识点:

参数化值函数近似、状态值函数与状态-动作值、函数近似、策略梯度、Actor-Critic



价值和策略近似逼近方法

课程回顾

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



参数化价值函数

本课程中解决的关键问题

- 之前所有模型的做法都是基于创建一个查询表，在表中维护状态值函数 $V(s)$ 或状态-动作值函数 $Q(s, a)$
- 当处理大规模马尔可夫决策过程 (MDP) 时，即：
 - 状态或者状态-动作空间非常大
 - 连续的状态或动作空间

是否仍然需要为每一个状态维护 $V(s)$ 或为每个状态-动作对维护 $Q(s, a)$?

- 例如
 - 围棋博弈 (10^{170} 的状态空间)
 - 直升机，自动驾驶汽车 (连续的状态空间)

主要内容

□ 大规模马尔可夫决策过程的解决方法

- 对状态/动作进行离散化或分桶
- 构建参数化的值函数估计

目录

Contents

01 对状态/动作进行离散化

02 参数化价值函数

01

对状态/动作
进行离散化


离散化连续马尔可夫决策过程

□ 对于连续状态马尔可夫决策过程，我们可以对状态空间进行离散化

- 例如，如果用2维连续值 (s_1, s_2) 表示状态，可以使用网格对状态空间进行切分从而转化为离散的状态值
- 记离散的状态值为 \bar{s}
- 离散化的马尔可夫决策过程可以表示为：


$$(\bar{S}, A, \{P_{\bar{s}a}\}, \gamma, R)$$

- 这样一来，就能够使用前述方法求解马尔可夫决策过程



对大型马尔可夫决策过程分桶

- 对于一个大型的离散状态马尔可夫决策过程，我们可以对状态值进一步分桶以进行采样聚合
 - 使用先验知识将相似的离散状态归类到一起
 - 例如，利用根据先验知识抽取出来的状态特征对状态进行聚类



离散化/分桶



□ 优点

- 操作简洁直观
- 高效
- 在处理许多问题时能够达到较好效果

□ 缺点

- 过于简单地表示价值函数 V
- 可能为每个离散区间假设一个常数值
- 维度灾难

$$S = R^n \Rightarrow \bar{S} = \{1, \dots, k\}^n$$



02

参数化
价值函数


参数化值函数近似

- 构建参数化（可学习的）函数来近似值函数

$$\begin{aligned}V_{\theta}(s) &\simeq V^{\pi}(s) \\ Q_{\theta}(s, a) &\simeq Q^{\pi}(s, a)\end{aligned}$$

- θ 是近似函数的参数，可以通过强化学习进行更新
- 参数化的方法将现有可见的状态泛化到没有见过的状态上

值函数近似的主要形式



- 一些函数近似
 - (一般的) 线性模型
 - 神经网络
 - 决策树
 - 最近邻
 - 傅立叶/小波基底
- 可微函数
 - (一般的) 线性模型
 - 神经网络
- 我们希望模型适合在**非稳态**的、**非独立同分布**的数据上训练
 - 因此参数化模型比树模型更适合

基于随机梯度下降 (SGD) 的值函数近似

- 目标：找到参数向量 θ 最小化值函数近似值与真实值之间的均方误差

$$J(\theta) = \mathbb{E}_{\pi} \left[\frac{1}{2} (V^{\pi}(s) - V_{\theta}(s))^2 \right]$$

- 误差减小的梯度方向

$$-\frac{\partial J(\theta)}{\partial \theta} = \mathbb{E}_{\pi} \left[(V^{\pi}(s) - V_{\theta}(s)) \frac{\partial V_{\theta}(s)}{\partial \theta} \right]$$

- 单次采样进行随机梯度下降

$$\begin{aligned} \theta &\leftarrow \theta - \alpha \frac{\partial J(\theta)}{\partial \theta} \\ &= \theta + \alpha (V^{\pi}(s) - V_{\theta}(s)) \frac{\partial V_{\theta}(s)}{\partial \theta} \end{aligned}$$

特征化状态

- 用一个特征向量表示状态

$$x(s) = \begin{bmatrix} x_1(s) \\ \vdots \\ x_k(s) \end{bmatrix}$$

- 以直升机控制问题为例

- 3D位置
- 3D速度 (位置的变化量)
- 3D加速度 (速度的变化量)





价值函数近似算法

目录

Contents

- 01 状态值函数近似
- 02 状态-动作值函数近似
- 03 案例分析



01

状态值函数
近似

线性状态值函数近似

- 用特征的线性组合表示价值函数

$$V_{\theta}(s) = \theta^T x(s)$$

- 目标函数是参数 θ 的二次函数

$$J(\theta) = \mathbb{E}_{\pi} \left[\frac{1}{2} (V^{\pi}(s) - \theta^T x(s))^2 \right]$$

- 因而随机梯度下降能够收敛到全局最优解上

$$\begin{aligned} \theta &\leftarrow \theta - \alpha \frac{\partial J(\theta)}{\partial \theta} \\ &= \theta + \alpha (V^{\pi}(s) - V_{\theta}(s)) x(s) \end{aligned}$$

步长 预测误差 特征值

蒙特卡洛状态值函数近似

$$\theta \leftarrow \theta + \alpha(V^\pi(s) - V_\theta(s))x(s)$$

- 我们用 $V^\pi(s)$ 表示真实的目标价值函数
- 在“训练数据”上运用监督学习对价值函数进行预测

$$\langle s_1, G_1 \rangle, \langle s_2, G_2 \rangle, \dots, \langle s_T, G_T \rangle$$

- 对于每个数据样本 $\langle s_t, G_t \rangle$

$$\theta \leftarrow \theta + \alpha(G_t - V_\theta(s))x(s_t)$$

- 蒙特卡洛预测至少能收敛到一个局部最优解
 - 在价值函数为线性的情况下可以收敛到全局最优

时序差分状态值函数近似

$$\theta \leftarrow \theta + \alpha(V^\pi(s) - V_\theta(s))x(s)$$

- 时序差分算法的目标 $r_{t+1} + \gamma V_\theta(s_{t+1})$ 是真实目标价值 $V_\pi(s_t)$ 的有偏采样

- 在“训练数据”上运用监督学习

$$\langle s_1, r_2 + \gamma V_\theta(s_2) \rangle, \langle s_2, r_3 + \gamma V_\theta(s_3) \rangle, \dots, \langle s_T, r_T \rangle$$

- 对于每个数据样本 $\langle s_t, r_{t+1} + \gamma V_\theta(s_{t+1}) \rangle$

$$\theta \leftarrow \theta + \alpha(r_{t+1} + \gamma V_\theta(s_{t+1}) - V_\theta(s))x(s_t)$$

- 线性情况下时序差分学习（接近）收敛到全局最优解



02

状态-动作
值函数近似

状态-动作值函数近似

- 对动作-状态值函数进行近似

$$Q_{\theta}(s, a) \simeq Q^{\pi}(s, a)$$

- 最小均方误差

$$J(\theta) = \mathbb{E}_{\pi} \left[\frac{1}{2} (Q^{\pi}(s, a) - Q_{\theta}(s, a))^2 \right]$$

- 在单个样本上进行随机梯度下降

$$\begin{aligned} \theta &\leftarrow \theta - \alpha \frac{\partial J(\theta)}{\partial \theta} \\ &= \theta + \alpha (Q^{\pi}(s, a) - Q_{\theta}(s, a)) \frac{\partial Q_{\theta}(s, a)}{\partial \theta} \end{aligned}$$

线性状态-动作值函数近似

- 用特征向量表示状态-动作对

$$x(s, a) = \begin{bmatrix} x_1(s, a) \\ \vdots \\ x_k(s, a) \end{bmatrix}$$

- 线性情况下，参数化后 Q 函数

$$Q_\theta(s, a) = \theta^\top x(s, a)$$

- 利用随机梯度下降更新

$$\begin{aligned} \theta &\leftarrow \theta - \alpha \frac{\partial J(\theta)}{\partial \theta} \\ &= \theta + \alpha \left(Q^\pi(s, a) - \theta^\top x(s, a) \right) x(s, a) \end{aligned}$$

时序差分状态-动作值函数近似

$$\theta \leftarrow \theta + \alpha(Q^\pi(s, a) - Q_\theta(s, a)) \frac{\partial Q_\theta(s, a)}{\partial \theta}$$


- 对于蒙特卡洛学习，目标是累计奖励 G_t

$$\theta \leftarrow \theta + \alpha(G_t - Q_\theta(s, a)) \frac{\partial Q_\theta(s, a)}{\partial \theta}$$

- 对于时序差分学习，目标是 $r_{t+1} + \gamma Q_\theta(s_{t+1}, a_{t+1})$

$$\theta \leftarrow \theta + \alpha(r_{t+1} + \gamma Q_\theta(s_{t+1}, a_{t+1}) - Q_\theta(s, a)) \frac{\partial Q_\theta(s, a)}{\partial \theta}$$

时序差分状态-动作值函数近似



- 策略评估：近似策略评估 $Q_\theta \approx Q^\pi$
- 策略改进： ϵ -贪心策略提升

时序差分学习参数更新过程

□ 对于TD(0), 时序差分学习的目标是

- 状态值函数

$$\begin{aligned}\theta &\leftarrow \theta + \alpha(V^\pi(s_t) - V_\theta(s)) \frac{\partial V_\theta(s_t)}{\partial \theta} \\ &= \theta + \alpha(r_{t+1} + \gamma V_\theta(s_{t+1}) - V_\theta(s)) \frac{\partial V_\theta(s_t)}{\partial \theta}\end{aligned}$$

- 动作-状态值函数

$$\begin{aligned}\theta &\leftarrow \theta + \alpha(Q^\pi(s, a) - Q_\theta(s, a)) \frac{\partial Q_\theta(s, a)}{\partial \theta} \\ &= \theta + \alpha(r_{t+1} + \gamma Q_\theta(s_{t+1}, a_{t+1}) - Q_\theta(s, a)) \frac{\partial Q_\theta(s, a)}{\partial \theta}\end{aligned}$$


□ 虽然 θ 在时序差分学习的目标中出现, 但是我们并不需要计算目标函数的梯度。想想这是为什么?



03

案例分析

案例分析: Deep Q-Network (DQN)




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

Volodymyr Mnih, Koray Kavukcuoglu, David Silver et al. Human-level control through deep reinforcement learning. Nature 2015.

案例分析：Deep Q-Network (DQN)

□ 使用深度神经网络表示Q函数



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

Volodymyr Mnih, Koray Kavukcuoglu, David Silver et al. Human-level control through deep reinforcement learning. Nature 2015.

案例分析：Deep Q-Network (DQN)

- 第*i*轮迭代中更新的Q-学习损失函数

$$L_i(\theta_i) = \mathbb{E}_{(s,a,r,s') \sim U(D)} \left[\underbrace{\left(r + \gamma \max_{a'} Q(s', a'; \theta_i^-) \right)}_{\text{目标Q值}} - \underbrace{Q(s, a; \theta_i)}_{\text{预测Q值}} \right]^2$$

- θ_i 是第*i*轮迭代中将要更新的网络参数
 - 通过标准的反向传播算法进行更新
- θ_i^- 是目标网络参数
 - 仅在 θ_i 每更新*C*步后进行更新
- $(s, a, r, s') \sim U(D)$: 样本从经验池*D*中均匀抽样
 - 这样做可以避免在近期经验上过拟合



策略梯度

参数化策略

- 我们能够将策略参数化

$$\pi_{\theta}(a|s)$$

策略可以是确定性的

$$a = \pi_{\theta}(s)$$

也可以是随机的

$$\pi_{\theta}(a|s) = P(a|s; \theta)$$

- θ 是策略的参数
- 将可见的已知状态泛化到未知的状态上
- 在本课程中我们主要讨论的是模型无关的强化学习

基于策略的强化学习

优点

- 具有更好的收敛性质
- 在高维度或连续的动作空间中更有效
 - 最重要的因素：基于值函数的方法，通常需要取最大值
- 能够学习出随机策略


缺点

- 通常会收敛到局部最优而非全局最优
- 评估一个策略通常不够高效并具有较大的方差 (variance)

策略梯度

- 对于随机策略 $\pi_{\theta}(a|s) = P(a|s; \theta)$
- 直觉上我们应该
 - 降低带来较低价值/奖励的动作出现的概率
 - 提高带来较高价值/奖励的动作出现的概率
- 一个离散动作空间维度为5的例子

1. 初始化 θ



3. 根据策略梯度更新 θ



2. 采取动作A2
观察到正的奖励

5. 根据策略梯度更新 θ



4. 采取动作A3
观察到负的奖励

单步马尔可夫决策过程中的策略梯度

□ 考虑一个简单的单步马尔可夫决策过程

- 起始状态为 $s \sim d(s)$
- 决策过程在进行一步决策后结束，获得奖励值为 r_{sa}

□ 策略的价值期望

$$J(\theta) = \mathbb{E}_{\pi_{\theta}}[r] = \sum_{s \in S} d(s) \sum_{a \in A} \pi_{\theta}(a|s) r_{sa}$$

$$\frac{\partial J(\theta)}{\partial \theta} = \sum_{s \in S} d(s) \sum_{a \in A} \frac{\partial \pi_{\theta}(a|s)}{\partial \theta} r_{sa}$$

似然比 (Likelihood Ratio)

- 似然比利用下列特性

$$\begin{aligned}\frac{\partial \pi_{\theta}(a|s)}{\partial \theta} &= \pi_{\theta}(a|s) \frac{1}{\pi_{\theta}(a|s)} \frac{\partial \pi_{\theta}(a|s)}{\partial \theta} \\ &= \pi_{\theta}(a|s) \frac{\partial \log \pi_{\theta}(a|s)}{\partial \theta}\end{aligned}$$

- 所以策略的价值期望可以写成

$$\begin{aligned}J(\theta) &= \mathbb{E}_{\pi_{\theta}}[r] = \sum_{s \in \mathcal{S}} d(s) \sum_{a \in \mathcal{A}} \pi_{\theta}(a|s) r_{sa} \\ \frac{\partial J(\theta)}{\partial \theta} &= \sum_{s \in \mathcal{S}} d(s) \sum_{a \in \mathcal{A}} \frac{\partial \pi_{\theta}(a|s)}{\partial \theta} r_{sa} \\ &= \sum_{s \in \mathcal{S}} d(s) \sum_{a \in \mathcal{A}} \pi_{\theta}(a|s) \frac{\partial \log \pi_{\theta}(a|s)}{\partial \theta} r_{sa} \\ &= \mathbb{E}_{\pi_{\theta}} \left[\frac{\partial \log \pi_{\theta}(a|s)}{\partial \theta} r_{sa} \right]\end{aligned}$$

这一结果可以通过从 $d(s)$ 中采样状态 s 和从 π_{θ} 中采样动作 a 来近似估计

策略梯度定理

- 策略梯度定理把似然比的推导过程泛化到**多步**马尔可夫决策过程
 - 用长期的价值函数 $Q^{\pi_{\theta}}(s, a)$ 代替前面的瞬时奖励 r_{sa}
- 策略梯度定理涉及
 - 起始状态目标函数 J_1 , 平均奖励目标函数 J_{avR} , 和平均价值目标函数 J_{avV}
- 定理
 - 对任意可微的策略 $\pi_{\theta}(a|s)$, 任意策略的目标函数 $J = J_1, J_{avR}, J_{avV}$, 其策略梯度是

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

详细证明过程请参考:

1. Rich Sutton's Reinforcement Learning: An Introduction (2nd Edition)第13章
2. 动手学强化学习策略梯度的附录

<https://hrl.boyuai.com/chapter/2/%E7%AD%96%E7%95%A5%E6%A2%AF%E5%BA%A6%E7%AE%97%E6%B3%95/>

蒙特卡洛策略梯度 (REINFORCE)

- 利用随机梯度上升更新参数
- 利用策略梯度定理
- 利用累计奖励值 G_t 作为 $Q^{\pi_\theta}(s, a)$ 的无偏采样

$$\Delta\theta_t = \alpha \frac{\partial \log \pi_\theta(a_t | s_t)}{\partial \theta} G_t$$

□ REINFORCE算法

initialize θ arbitrarily

for each episode $\{s_1, a_1, r_2, \dots, s_{T-1}, a_{T-1}, r_T\} \sim \pi_\theta$ do

for $t = 1$ to $T - 1$ do

$$\theta \leftarrow \theta + \alpha \frac{\partial}{\partial \theta} \log \pi_\theta(a_t | s_t) G_t$$

end for


end for

return θ

蒙特卡洛策略梯度 (REINFORCE)



$$\Delta\theta_t = \alpha \frac{\partial \log \pi_\theta(a_t | s_t)}{\partial \theta} G_t$$

- 可通过多次roll-out的 G_t 平均值来逼近 $Q(s_t, a_t)$



$$\tilde{G}_t = \frac{1}{N} \sum_{i=1}^n G_t^{(i)}$$

Puck World 冰球世界示例



- 连续的动作对冰球施加较小的力
- 冰球接近目标可以得到奖励
- 目标位置每30秒重置一次
- 使用蒙特卡洛策略梯度方法训练策略

Softmax随机策略

- Softmax策略是一种非常常用的随机策略

$$\pi_{\theta}(a|s) = \frac{e^{f_{\theta}(s,a)}}{\sum_{a'} e^{f_{\theta}(s,a')}}$$

- 式中, $f_{\theta}(s,a)$ 是用 θ 参数化的状态-动作对得分函数, 可以预先定义

- 其对数似然的梯度是

$$\begin{aligned} \frac{\partial \log \pi_{\theta}(a|s)}{\partial \theta} &= \frac{\partial f_{\theta}(s,a)}{\partial \theta} - \frac{1}{\sum_{a'} e^{f_{\theta}(s,a')}} \sum_{a''} e^{f_{\theta}(s,a'')} \frac{\partial f_{\theta}(s,a'')}{\partial \theta} \\ &= \frac{\partial f_{\theta}(s,a)}{\partial \theta} - \mathbb{E}_{a' \sim \pi_{\theta}(a'|s)} \left[\frac{\partial f_{\theta}(s,a')}{\partial \theta} \right] \end{aligned}$$

Softmax随机策略

- Softmax策略是一种非常常用的随机策略

$$\pi_{\theta}(a|s) = \frac{e^{f_{\theta}(s,a)}}{\sum_{a'} e^{f_{\theta}(s,a')}}$$

- 式中, $f_{\theta}(s, a)$ 是用 θ 参数化的状态-动作对得分函数, 可以预先定义

- 举线性得分函数为例, 则有

$$f_{\theta}(s, a) = \theta^T x(s, a)$$

$$\begin{aligned} \frac{\partial \log \pi_{\theta}(a|s)}{\partial \theta} &= \frac{\partial f_{\theta}(s, a)}{\partial \theta} - \mathbb{E}_{a' \sim \pi_{\theta}(a'|s)} \left[\frac{\partial f_{\theta}(s, a')}{\partial \theta} \right] \\ &= x(s, a) - \mathbb{E}_{a' \sim \pi_{\theta}(a'|s)} [x(s, a')] \end{aligned}$$



Actor-Critic

REINFORCE 存在的问题

□ 基于片段式数据的任务

- 通常情况下，任务需要有**终止状态**，REINFORCE才能直接计算累计折扣奖励

□ 低数据利用效率

- 实际中，REINFORCE需要**大量的**训练数据

□ 高训练方差 (**最重要的缺陷**)

- 从单个或多个片段中采样到的值函数具有**很高的方差**

Actor-Critic

Actor-Critic的思想

- REINFORCE策略梯度方法：使用蒙特卡洛采样直接估计 (s_t, a_t) 的值 G_t
- 为什么不建立一个可训练的值函数 Q_ϕ 来完成这个估计过程？

演员 (Actor) 和评论家 (Critic)

演员 $\pi_\theta(a|s)$

采取动作使评论家满意的策略



评论家 $Q_\phi(s, a)$

学会准确估计演员策略所采取动作价值的值函数

Actor-Critic训练

评论家Critic: $Q_{\Phi}(s, a)$

- 学会准确估计当前演员策略 (actor policy) 的动作价值

$$Q_{\Phi}(s, a) \simeq r(s, a) + \gamma \mathbb{E}_{s' \sim p(s'|s, a), a' \sim \pi_{\theta}(a'|s')} [Q_{\Phi}(s', a')]$$

演员Actor: $\pi_{\theta}(a|s)$

- 学会采取使critic满意的动作

$$J(\theta) = \mathbb{E}_{s \sim p, \pi_{\theta}} [\pi_{\theta}(a|s) Q_{\Phi}(s, a)]$$

$$\frac{\partial J(\theta)}{\partial \theta} = \mathbb{E}_{\pi_{\theta}} \left[\frac{\partial \log \pi_{\theta}(a|s)}{\partial \theta} Q_{\Phi}(s, a) \right]$$

A2C: Advantageous Actor-Critic

- 思想：通过减去一个基线函数来标准化评论家的打分
 - 更多信息指导：降低较差动作概率，提高较优动作概率
 - 进一步降低方差
- 优势函数 (Advantage Function)

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



A2C: Advantageous Actor-Critic

□ 状态-动作值和状态值函数

$$\begin{aligned} Q^\pi(s, a) &= r(s, a) + \gamma \mathbb{E}_{s' \sim p(s'|s, a), a' \sim \pi_\theta(a'|s')} [Q_\Phi(s', a')] \\ &= r(s, a) + \gamma \mathbb{E}_{s' \sim p(s'|s, a)} [V^\pi(s')] \end{aligned}$$

□ 因此我们只需要拟合状态值函数来拟合优势函数

$$\begin{aligned} A^\pi(s, a) &= Q^\pi(s, a) - V^\pi(s) \\ &= r(s, a) + \gamma \mathbb{E}_{s' \sim p(s'|s, a)} [V^\pi(s')] - V^\pi(s) \\ &\simeq r(s, a) + \gamma V^\pi(s') - V^\pi(s) \end{aligned}$$



采样下一个状态 s'

价值和策略的近似逼近方法总结

- 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
- 参数化的价值函数和策略
- 通过链式法则，价值函数的参数可以被直接学习
- 通过likelihood-ratio方法，可以用advantage对策略的参数进行学习
- 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

THANK YOU

策略梯度定理：平均奖励原则

□ 平均奖励目标函数

$$J(\pi) = \lim_{n \rightarrow \infty} \frac{1}{n} \mathbb{E}[r_1 + r_2 + \dots + r_n | \pi] = \sum_s d^\pi(s) \sum_a \pi(a|s) r(s, a)$$

$$Q^\pi(s, a) = \sum_{t=1}^{\infty} \mathbb{E}[r_t - J(\pi) | s_0 = s, a_0 = a, \pi]$$

$$\begin{aligned} \frac{\partial V^\pi(s)}{\partial \theta} &\stackrel{\text{def}}{=} \frac{\partial}{\partial \theta} \sum_a \pi(a|s) Q^\pi(s, a), \quad \forall s \\ &= \sum_a \left[\frac{\partial \pi(a|s)}{\partial \theta} Q^\pi(s, a) + \pi(a|s) \frac{\partial}{\partial \theta} Q^\pi(s, a) \right] \\ &= \sum_a \left[\frac{\partial \pi(a|s)}{\partial \theta} Q^\pi(s, a) + \pi(a|s) \frac{\partial}{\partial \theta} \left(r(s, a) - J(\pi) + \sum_{s'} P_{ss'}^a V^\pi(s') \right) \right] \\ &= \sum_a \left[\frac{\partial \pi(a|s)}{\partial \theta} Q^\pi(s, a) + \pi(a|s) \left(-\frac{\partial J(\pi)}{\partial \theta} + \frac{\partial}{\partial \theta} \sum_{s'} P_{ss'}^a V^\pi(s') \right) \right] \\ \Rightarrow \frac{\partial J(\pi)}{\partial \theta} &= \sum_a \left[\frac{\partial \pi(a|s)}{\partial \theta} Q^\pi(s, a) + \pi(a|s) \sum_{s'} P_{ss'}^a \frac{\partial V^\pi(s')}{\partial \theta} \right] - \frac{\partial V^\pi(s)}{\partial \theta} \end{aligned}$$

策略梯度定理：平均奖励原则

□ 目标函数

$$\begin{aligned}
 \frac{\partial J(\pi)}{\partial \theta} &= \sum_a \left[\frac{\partial \pi(a|s)}{\partial \theta} Q^\pi(s, a) + \pi(a|s) \sum_{s'} P_{ss'}^a \frac{\partial V^\pi(s')}{\partial \theta} \right] - \frac{\partial V^\pi(s)}{\partial \theta} \\
 \sum_s d^\pi(s) \frac{\partial J(\pi)}{\partial \theta} &= \sum_s d^\pi(s) \sum_a \frac{\partial \pi(a|s)}{\partial \theta} Q^\pi(s, a) + \sum_s d^\pi(s) \sum_a \pi(a|s) \sum_{s'} P_{ss'}^a \frac{\partial V^\pi(s')}{\partial \theta} - \sum_s d^\pi(s) \frac{\partial V^\pi(s)}{\partial \theta} \\
 \sum_s d^\pi(s) \sum_a \pi(a|s) \sum_{s'} P_{ss'}^a \frac{\partial V^\pi(s')}{\partial \theta} &= \sum_s \sum_a \sum_{s'} d^\pi(s) \pi(a|s) P_{ss'}^a \frac{\partial V^\pi(s')}{\partial \theta} \\
 &= \sum_s \sum_{s'} d^\pi(s) \left(\sum_a \pi(a|s) P_{ss'}^a \right) \frac{\partial V^\pi(s')}{\partial \theta} = \sum_s \sum_{s'} d^\pi(s) P_{ss'} \frac{\partial V^\pi(s')}{\partial \theta} \\
 &= \sum_{s'} \left(\sum_s d^\pi(s) P_{ss'} \right) \frac{\partial V^\pi(s')}{\partial \theta} = \sum_{s'} d^\pi(s') \frac{\partial V^\pi(s')}{\partial \theta} \\
 \Rightarrow \sum_s d^\pi(s) \frac{\partial J(\pi)}{\partial \theta} &= \sum_s d^\pi(s) \sum_a \frac{\partial \pi(a|s)}{\partial \theta} Q^\pi(s, a) + \sum_{s'} d^\pi(s') \frac{\partial V^\pi(s')}{\partial \theta} - \sum_s d^\pi(s) \frac{\partial V^\pi(s)}{\partial \theta} \\
 \Rightarrow \frac{\partial J(\pi)}{\partial \theta} &= \sum_s d^\pi(s) \sum_a \frac{\partial \pi(a|s)}{\partial \theta} Q^\pi(s, a)
 \end{aligned}$$

策略梯度定理：起始价值原则

□ 起始状态价值目标

$$J(\pi) = \mathbb{E} \left[\sum_{t=1}^{\infty} \gamma^{t-1} r_t \mid s_0, \pi \right]$$

$$Q^\pi(s, a) = \mathbb{E} \left[\sum_{k=1}^{\infty} \gamma^{k-1} r_{t+k} \mid s_t = s, a_t = a, \pi \right]$$

$$\frac{\partial V^\pi(s)}{\partial \theta} = \frac{\partial}{\partial \theta} \sum_a \pi(s, a) Q^\pi(s, a), \quad \forall s$$

$$= \sum_a \left[\frac{\partial \pi(s, a)}{\partial \theta} Q^\pi(s, a) + \pi(s, a) \frac{\partial}{\partial \theta} Q^\pi(s, a) \right]$$

$$= \sum_a \left[\frac{\partial \pi(s, a)}{\partial \theta} Q^\pi(s, a) + \pi(s, a) \frac{\partial}{\partial \theta} \left(r(s, a) + \sum_{s'} \gamma P_{ss'}^a V^\pi(s') \right) \right]$$

$$= \sum_a \frac{\partial \pi(s, a)}{\partial \theta} Q^\pi(s, a) + \sum_a \pi(s, a) \gamma \sum_{s'} P_{ss'}^a \frac{\partial V^\pi(s')}{\partial \theta}$$

策略梯度定理：起始价值原则

□ 起始状态价值目标

$$\begin{aligned} \frac{\partial V^\pi(s)}{\partial \theta} &= \sum_a \frac{\partial \pi(s, a)}{\partial \theta} Q^\pi(s, a) + \sum_a \pi(s, a) \gamma \sum_{s_1} P_{ss_1}^a \frac{\partial V^\pi(s_1)}{\partial \theta} \\ \sum_a \frac{\partial \pi(s, a)}{\partial \theta} Q^\pi(s, a) &= \gamma^0 \Pr(s \rightarrow s, 0, \pi) \sum_a \frac{\partial \pi(s, a)}{\partial \theta} Q^\pi(s, a) \\ \sum_a \pi(s, a) \gamma \sum_{s_1} P_{ss_1}^a \frac{\partial V^\pi(s_1)}{\partial \theta} &= \sum_{s_1} \sum_a \pi(s, a) \gamma P_{ss_1}^a \frac{\partial V^\pi(s_1)}{\partial \theta} \\ &= \sum_{s_1} \gamma P_{ss_1} \frac{\partial V^\pi(s_1)}{\partial \theta} = \gamma^1 \sum_{s_1} \Pr(s \rightarrow s_1, 1, \pi) \frac{\partial V^\pi(s_1)}{\partial \theta} \\ \frac{\partial V^\pi(s_1)}{\partial \theta} &= \sum_a \frac{\partial \pi(s_1, a)}{\partial \theta} Q^\pi(s_1, a) + \gamma^1 \sum_{s_2} \Pr(s_1 \rightarrow s_2, 1, \pi) \frac{\partial V^\pi(s_2)}{\partial \theta} \end{aligned}$$

策略梯度定理：起始价值原则

□ 起始状态价值目标

$$\begin{aligned}
 \frac{\partial V^\pi(s)}{\partial \theta} &= \gamma^0 \Pr(s \rightarrow s, 0, \pi) \sum_a \frac{\partial \pi(s, a)}{\partial \theta} Q^\pi(s, a) + \gamma^1 \sum_{s_1} \Pr(s \rightarrow s_1, 1, \pi) \sum_a \frac{\partial \pi(s_1, a)}{\partial \theta} Q^\pi(s_1, a) \\
 &\quad + \gamma^2 \sum_{s_1} \Pr(s \rightarrow s_1, 1, \pi) \sum_{s_2} \Pr(s_1 \rightarrow s_2, 1, \pi) \frac{\partial V^\pi(s_2)}{\partial \theta} \\
 &= \gamma^0 \Pr(s \rightarrow s, 0, \pi) \sum_a \frac{\partial \pi(s, a)}{\partial \theta} Q^\pi(s, a) + \gamma^1 \sum_{s_1} \Pr(s \rightarrow s_1, 1, \pi) \sum_a \frac{\partial \pi(s_1, a)}{\partial \theta} Q^\pi(s_1, a) \\
 &\quad + \gamma^2 \sum_{s_2} \Pr(s \rightarrow s_2, 2, \pi) \frac{\partial V^\pi(s_2)}{\partial \theta} \\
 &= \sum_{k=0}^{\infty} \sum_x \gamma^k \Pr(s \rightarrow x, k, \pi) \sum_a \frac{\partial \pi(x, a)}{\partial \theta} Q^\pi(x, a) = \sum_x \sum_{k=0}^{\infty} \gamma^k \Pr(s \rightarrow x, k, \pi) \sum_a \frac{\partial \pi(x, a)}{\partial \theta} Q^\pi(x, a) \\
 \Rightarrow \frac{\partial J(\pi)}{\partial \theta} &= \frac{\partial V^\pi(s_0)}{\partial \theta} = \sum_s \sum_{k=0}^{\infty} \gamma^k \Pr(s_0 \rightarrow s, k, \pi) \sum_a \frac{\partial \pi(s, a)}{\partial \theta} Q^\pi(s, a) = \sum_s d^\pi(s) \sum_a \frac{\partial \pi(s, a)}{\partial \theta} Q^\pi(s, a)
 \end{aligned}$$