

Homework for “Algorithms for Big-Data Analysis”

Beijing International Center for Mathematical Research
Peking University

February 17, 2024

Note: Please write up your solutions independently. If you get significant help from others, write down the source of references. A formal mathematical proof for all your claims is required.

1. 考虑有限情形的MDP (S, A, P, R, γ) , 其中 S 是有限个离散状态的集合, A 是有限个离散动作的集合, R 是奖励函数, $\gamma \in (0, 1)$ 是折扣因子。给定时刻 t 的状态 s 和动作 a , 下一时刻转移到状态 s' 的概率是 $P(s' | s, a) = P(s_{t+1} = s' | s_t = s, a_t = a)$ 。令 $V(s)$ 为价值函数, 定义Bellman 算子 B :

$$BV(s) = \max_a \left\{ R(s, a) + \gamma \sum_{s' \in S} P(s' | s, a) V(s') \right\}, \quad \forall s \in S.$$

- (a) 证明算子 B 是压缩映射, 即:

$$\|BV - BV'\|_\infty \leq \gamma \|V - V'\|_\infty,$$

其中 $\|V - V'\|_\infty = \max_s |V(s) - V'(s)|$ 。

- (b) 从 V_0 开始执行迭代算法: $V_{k+1} = BV_k$ 。对于任意 $k > 0$, 证明:

$$\|V_{n+k} - V_n\|_\infty \leq \frac{\gamma^n}{1-\gamma} \|V_1 - V_0\|_\infty.$$

2. 令考虑有限步MDP (S, A, s_1, P, R, H) , 其中 S 为状态集合, A 为动作集合, s_1 为初始状态, P 为转移概率矩阵, R 为奖励矩阵, H 为终止时间, γ 为折扣因子。定义 $\pi(s, a)$ 是在状态 s 根据随机策略 π 执行动作 a 的概率。定义 $\tau = (s_1, a_1, s_2, \dots, a_{H-1}, s_H)$ 是从状态 s_1 出发, 执行策略 π 产生的轨道(状态-动作对), 即 $a_t \sim \pi(s_t, \cdot)$ 。

- (a) 写出轨道 τ 的概率表达式 $D^\pi(\tau)$ 。

- (b) 定义 $\rho(\pi)$ 是有限步总奖励的均值, 即:

$$\rho(\pi) = \mathbb{E} \left[\sum_{t=1}^H \gamma^{t-1} r_t | \pi, s_1 \right].$$

令 $R(\tau)$ 是在轨道 τ 获得的总奖励。写出 $\rho(\pi)$ 关于 $R(\tau)$ 的表达式。

(c) 假设 $\pi_\theta(s, a)$ 是参数化之后的策略, 其中 θ 是参数。证明

$$\nabla_{\theta} \rho(\pi_{\theta}) = \mathbb{E}_{\tau} [R(\tau) \nabla_{\theta} \log(D^{\pi_{\theta}}(\tau))] = \mathbb{E}_{\tau} \left[R(\tau) \sum_{t=1}^{H-1} \nabla_{\theta} \log(\pi_{\theta}(s_t, a_t)) \right].$$

(d) 给定状态 s_t 和参数 θ , 假设 $b_t(s_t)$ 条件独立于 π_θ 产生的抽样。证明:

$$\mathbb{E}_{\tau} \left[\sum_{t=1}^{H-1} b_t(s_t) \frac{\partial}{\partial \theta_j} \log(\pi_{\theta}(s_t, a_t)) \mid \theta, s_1 \right] = 0.$$

(e) 给出满足(d)里条件的一种 $b_t(s_t)$ 。