

知識工学

岡山大学大学院

講師 竹内孔一

本日の内容

- 強化学習

- 最適価値関数

- Q学習

強化学習の枠組

■ 状態 s_t (state)

- エージェントが時刻 t で取る状態

■ 行動 a_t (action)

- エージェントが時刻 t で取る行動

■ 報酬 r_t (reward) ・ 収益 R_t (return)

- 報酬: エージェントが行動により得る値
- 収益: 時刻 t (または $t+1$)以降に得られる報酬の総量

■ 政策/方策 $\pi(s,a)$ (policy)

- 状態 s のときに行動 a をとる関数

■ 価値関数 $V(s)$ (state-value function)

- 状態 s で将来得られる報酬の総量(=収益)の期待値 (つまり予測値)

■ 行動価値関数 $Q(s,a)$ (action-value function)

- 状態 s で行動 a を取るとき将来得られる報酬の総量(=収益)の期待値

■ 環境モデル

- 状態 s で行動 a を取ったとき、次にどういう状態に行くか、報酬はあるかあるとしたらいくらか、エージェントに与える

強化学習の基本枠組(これで全部)

■ マルコフ決定過程

■ 状態遷移モデル

■ エージェントの行動

■ 状態 s_t をで行動 a_t を選択

■ 環境から次状態 s_{t+1} と報酬 r_{t+1} を得る

■ (注) 行動 a_t で報酬 r_{t+1} (教科書などによるので注意)

■ 収益

■ これから得られる報酬の総量 (t は T まで)

■ 将来の収益は割り引いて考える γ (割引率)

■ 状態価値 $V(s)$ vs. 行動価値 $Q(s, a)$

■ (ある状態 s での価値) vs. (状態 s で行動 a の時の価値)

■ 政策 π によって違う値をとる

■ 状態価値 $V^\pi(s)$ vs. 行動価値 $Q^\pi(s, a)$

■ 期待値を求めて、行動選択の指針にする

■ 状態価値を使うか行動価値を使うかはユーザが選択

■ 学習方法 (状態 $V(s)$ か 行動 $Q(s, a)$ の学習か2種)

■ $V(s)$ の学習: TD 学習 (Temporal difference learning)

■ 各状態 s での価値 $V(s)$ が数値として求まる

■ $Q(s, a)$ の学習(1): 方策オン型学習

■ **SARSA** (方策 π に従った学習法)

■ $Q(s, a)$ の学習(2): 方策オフ型学習

■ **Q-learning** (方策は関係無く価値最大の行動をとると固定) 簡単に利用できる

最適政策

■最適政策

■状態 s における期待収益が高い政策

$$V^{\pi}(s) \geq V^{\pi'}(s)$$

■最適状態価値関数

$$V^*(s) = \max_{\pi} V^{\pi}(s)$$

$$V^*(s) = \max_a Q^{\pi^*}(s, a)$$

■最適行動価値関数 (ある状態での行動価値)

$$Q^*(s, a) = \max_{\pi} Q^{\pi}(s, a)$$

$$Q^*(s, a) = E\{r_{t+1} + \gamma V^*(s_{t+1}) | s_t, a_t = a\}$$

Q(s,a) 行動価値の学習

■Q(s,a)の行動価値学習

■方策オン型 SARSA

■方策に従った行動価値

■方策オフ型 Q-learning

■最適政策に従った行動価値

■Q-learning

■ある状態である行動を取るときの価値を行動価値最大で計算. 方策と無関係に学習

$$\begin{aligned} Q(s_t, a_t) &\leftarrow (1 - \alpha)Q(s_t, a_t) + \alpha \left\{ r_{t+1} + \gamma \max_a Q(s_{t+1}, a) \right\} \\ &\leftarrow Q(s_t, a_t) + \alpha \left\{ r_{t+1} + \gamma \max_a Q(s_{t+1}, a) - \alpha Q(s_t, a_t) \right\} \end{aligned}$$

α は学習率

$Q(s,a)$ 行動価値の学習

■SARSA

- ある状態である行動を取るときの行動価値
- 方策で行動 a を決定
- $s_t, a_t, r_t, s_{t+1}, a_{t+1}$ の頭文字

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha \{r_{t+1} + \gamma Q(s_{t+1}, a) - Q(s_t, a_t)\}$$

注意: 教科書にあわせて r_{t+1} で記述している

結局TD学習の形と同じ

$$V(s) \leftarrow V(s) + \alpha \{r_{t+1} + \gamma V(s') - V(s)\}$$