

Rappel: processus de décision markovien

- Un **processus de décision markovien** (*Markov decision process*, ou **MDP**) est défini par:
 - ◆ un **ensemble d'états** S (incluant un état initial s_0)
 - ◆ un **ensemble d'actions** possibles $Actions(s)$ (ou $A(s)$) lorsque je me trouve à l'état s
 - ◆ un **modèle de transition** $P(s'|s, a)$, où $a \in A(s)$
 - ◆ une **fonction de récompense** $R(s)$ (utilité d'être dans l'état s)
- Un **plan (politique)** π est un ensemble de décisions qui associe un état s à une action $a = \pi(s)$

Rappel: processus de décision markovien

- La **fonction de valeur** $V(s)$ d'un plan est donnée par les équations

$$V(s) = R(s) + \gamma \sum_{s' \in S} P(s'|s, \pi(s)) V(s')$$


où γ est un facteur d'escompte donné

- Plutôt que $V(s)$, on note parfois $V(\pi, s)$, ou $U^\pi(s)$ dans le livre
- **NOUVEAU**: on va supposer l'existence d'**états terminaux**
 - ◆ lorsque l'agent atteint cet état, la simulation est arrêtée
 - ◆ on s'intéresse à la somme des récompenses jusqu'à l'atteinte d'un état terminal
 - » ex.: au tic-tac-toe, l'état terminal est une grille de fin de partie (c.-à-d. une grille complète ou une grille où un des joueurs a gagné)

Apprentissage par renforcement passif

- **Définition:** soit un plan π donné, apprendre la fonction de valeur sans connaître $P(s'|s, a)$
- **Exemple illustratif:** déplacement sur une grille 3 x 4

- ◆ plan π illustré par les flèches
- ◆ $R(s) = -0.04$ partout sauf aux états terminaux
- ◆ l'environnement est stochastique
- ◆ l'agent arrête aux états terminaux
- ◆ on utilise $\gamma=1$



Apprentissage par renforcement passif

- **Définition:** soit un plan π donné, apprendre la fonction de valeur sans connaître $P(s'|s, a)$
- Puisqu'on ne connaît pas $P(s'|s, a)$ on doit apprendre à partir d'**essais** (*trials*)
 1. $(1,1)_{-.04} \rightarrow (1,2)_{-.04} \rightarrow (1,3)_{-.04} \rightarrow (1,2)_{-.04} \rightarrow (1,3)_{-.04} \rightarrow (2,3)_{-.04} \rightarrow (3,3)_{-.04} \rightarrow (4,3)_{+1}$
 2. $(1,1)_{-.04} \rightarrow (1,2)_{-.04} \rightarrow (1,3)_{-.04} \rightarrow (2,3)_{-.04} \rightarrow (3,3)_{-.04} \rightarrow (3,2)_{-.04} \rightarrow (3,3)_{-.04} \rightarrow (4,3)_{+1}$
 3. $(1,1)_{-.04} \rightarrow (2,1)_{-.04} \rightarrow (3,1)_{-.04} \rightarrow (3,2)_{-.04} \rightarrow (4,2)_{-1}$
- Comment estimer la fonction de valeurs $V(s)$ à partir de ces essais?

Approche par estimation directe

- Approche la plus simple: **calculer la moyenne de ce qui est observé** dans les essais

- Essais

1. $(1,1)_{-.04} \rightarrow (1,2)_{-.04} \rightarrow (1,3)_{-.04} \rightarrow (1,2)_{-.04} \rightarrow (1,3)_{-.04} \rightarrow (2,3)_{-.04} \rightarrow (3,3)_{-.04} \rightarrow (4,3)_{+1}$
2. $(1,1)_{-.04} \rightarrow (1,2)_{-.04} \rightarrow (1,3)_{-.04} \rightarrow (2,3)_{-.04} \rightarrow (3,3)_{-.04} \rightarrow (3,2)_{-.04} \rightarrow (3,3)_{-.04} \rightarrow (4,3)_{+1}$
3. $(1,1)_{-.04} \rightarrow (2,1)_{-.04} \rightarrow (3,1)_{-.04} \rightarrow (3,2)_{-.04} \rightarrow (4,2)_{-1}$

- Estimation de $V((1,1))$

- ◆ dans l'essai 1, la somme des récompenses à partir de $(1,1)$ est 0.72
- ◆ dans l'essai 2, on observe également 0.72
- ◆ dans l'essai 3, on observe plutôt -1.16
- ◆ l'estimation directe de $V((1,1))$ est donc $(0.72+0.72-1.16)/3 = 0.09333$

Approche par estimation directe

- Approche la plus simple: **calculer la moyenne de ce qui est observé** dans les essais
- Essais
 1. $(1,1)_{-.04} \rightarrow (1,2)_{-.04} \rightarrow (1,3)_{-.04} \rightarrow (1,2)_{-.04} \rightarrow (1,3)_{-.04} \rightarrow (2,3)_{-.04} \rightarrow (3,3)_{-.04} \rightarrow (4,3)_{+1}$
 2. $(1,1)_{-.04} \rightarrow (1,2)_{-.04} \rightarrow (1,3)_{-.04} \rightarrow (2,3)_{-.04} \rightarrow (3,3)_{-.04} \rightarrow (3,2)_{-.04} \rightarrow (3,3)_{-.04} \rightarrow (4,3)_{+1}$
 3. $(1,1)_{-.04} \rightarrow (2,1)_{-.04} \rightarrow (3,1)_{-.04} \rightarrow (3,2)_{-.04} \rightarrow (4,2)_{-1}$
- Estimation de $V((1,2))$
 - ◆ dans l'essai 1, l'état $(1,2)$ est visité deux fois, avec des sommes de récompenses à partir de $(1,2)$ de 0.76 et 0.84
 - ◆ dans l'essai 2, on observe 0.76
 - ◆ l'essai 3 ne visite pas $(1,2)$
 - ◆ l'estimation directe de $V((1,2))$ est donc $(0.76+0.84+0.76)/3 = 0.78666$