

# Processus de décision markovien

## Cours 10: Décisions séquentielles - PDM

Stéphane Airiau

Université Paris-Dauphine

**Définition** (Processus décisionnel de Markov)

Un *Processus décisionnel de Markov* est un tuple  $\langle S, A, T, R, \gamma \rangle$  où

- $S$  est un ensemble fini d'états
- $A$  est un ensemble fini d'actions
- $T$  est une matrice de transition  
 $T_{ss'}^a = \mathbb{P}[S_{t+1} = s' \mid S_t = s, A_t = a]$  probabilité d'arriver dans l'état  $s'$  à l'instant  $+1$  quand on a pris l'action  $a$  dans l'état  $s$  à l'instant  $t$
- $R$  est le vecteur de récompenses  
 $R_s^a = \mathbb{E}[R_{t+1} \mid S_t = s, A_t = a]$  valeur moyenne obtenue après avoir pris l'action  $a$  dans l'état  $s$
- un ensemble d'état initial
- parfois un ensemble d'états terminaux

## Les composants d'un agent : politique

C'est ce qui gouverne le comportement de l'agent

**politique déterministe** : La fonction associée à chaque état **une action**

$$\pi: S \mapsto A$$

3	→	→	→	+1
2	↑		↑	-1
1	START	→	↑	←
	1	2	3	4

politique optimale pour  
un pénalité de 0.03 par  
déplacement

## Focus pour le cours

---

- problèmes itératifs en continue.
- objectif : maximiser la somme "avec dévaluation"  $G_t = \sum_{k=0}^{\infty} \gamma^k r_{t+k+1}$ 
  - Pour éviter une récompense infinie si on tombe dans des cycles
  - Le futur reste incertain! Bon compromis entre court et long terme
  - Tendance naturelle vers le court terme
  - Mathématiquement, c'est quand même pratique!
- la fonction de transition est stochastique
- la fonction de récompense est connue


Comment trouver la meilleure politique ?

On va s'aider de deux quantités

$v^*(s)$  quelle est la valeur de me trouver dans l'état  $s$  puis de continuer avec la politique optimale

$q^*(s,a)$  quelle est la valeur de prendre l'action  $a$  dans l'état  $s$  puis de continuer avec la politique optimale

$\pi^*(s)$  politique optimale pour l'état  $s$  (i.e. quelle est la meilleure action).



## Valeur optimale d'un état $v^*(s)$

---

- on calcule la valeur espérée en supposant qu'on suive la politique optimale
- on prend la moyenne pondérée des récompenses escomptée
- ➡ comme dans expectimax!


$$v^*(s) = \max_{a \in A} q^*(s, a)$$

$$q^*(s, a) = R_s^a + \gamma \sum_{s' \in S} T_{ss'}^a v^*(s')$$

donc

$$v^*(s) = \max_{a \in A} \left[ R_s^a + \gamma \sum_{s' \in S} T_{ss'}^a v^*(s') \right]$$

# Idée d'itération sur les valeurs



# Value Iteration

---

```
1  for each  $s \in S$  and  $k \in \mathbb{N}$ 
2     $V_k(s) \leftarrow 0$ 
3
4  repeat for  $k=0$  to ...
5
6    for each  $s \in S$ 
7
8       $V_{k+1}(s) \leftarrow \max_{a \in A} \left[ R_s^a + \gamma \sum_{s' \in S} T_{ss'}^a V_k(s') \right]$       /* mise à jour */
9
10 until convergence
```

## Value Iteration – plus efficace pour la mémoire

---

```
1  for each  $s \in S$ 
2     $V(s) \leftarrow 0$ 
3
4  repeat
5
6    for each  $s \in S$ 
7
8       $V(s) \leftarrow \max_{a \in A} \left[ R_s^a + \gamma \sum_{s' \in S} T_{ss'}^a V(s') \right]$            /* mise à jour */
9
10 until convergence
```

## Value Iteration – avec test de convergence

---

```
1  for each  $s \in S$ 
2     $V(s) \leftarrow 0$ 
3
4  repeat
5     $\Delta \leftarrow 0$                                 /* mesure le plus grand changement */
6    for each  $s \in S$ 
7       $v \leftarrow V(s)$                             /* sauvegarde l'ancienne valeur pour mesurer le changement */
8       $V(s) \leftarrow \max_{a \in A} \left[ R_s^a + \gamma \sum_{s' \in S} T_{ss'}^a V(s') \right]$           /* mise à jour */
9       $\Delta \leftarrow \max(\Delta, |v - V(s)|)$       /* mise à jour du plus grand changement*/
10 until  $\Delta < \epsilon$                             /* test convergence */
```

- On n'a pas de politique explicite
- On a un théorème de convergence

## Itération sur les valeurs : $k = 0$

0.00	0.60	0.00	0.00
0.00		0.00	0.00
0.00	0.00	0.00	0.00

$$\begin{aligned}r &= 0 \\ \gamma &= 0.9 \\ \text{bruit} &= 0.2\end{aligned}$$

## Itération sur les valeurs : $k = 1$

0.00	0.60	0.00	+1.00
0.00		0.00	-1.00
0.00	0.00	0.00	0.00

$$\begin{aligned}r &= 0 \\ \gamma &= 0.9 \\ \text{bruit} &= 0.2\end{aligned}$$

## Itération sur les valeurs : $k = 2$

0.00	0.00	0.72	+1.00
0.00		0.00	-1.00
0.00	0.00	0.00	0.00

$$r = 0$$

$$\gamma = 0.9$$

$$\text{bruit} = 0.2$$

## Itération sur les valeurs : $k = 3$

0.00	0.52	0.78	+1.00
0.00		0.43	-1.00
0.00	0.00	0.00	0.00

$$\begin{aligned}r &= 0 \\ \gamma &= 0.9 \\ \text{bruit} &= 0.2\end{aligned}$$

## Itération sur les valeurs : $k = 4$

0.37	0.66	0.83	+1.00
0.00		0.51	-1.00
0.00	0.00	0.31	0.00

$$\begin{aligned}r &= 0 \\ \gamma &= 0.9 \\ \text{bruit} &= 0.2\end{aligned}$$

## Itération sur les valeurs : $k = 5$

0.51	0.72	0.84	+1.00
0.27		0.55	-1.00
0.00	0.22	0.37	0.13

$$r = 0$$

$$\gamma = 0.9$$

$$\text{bruit} = 0.2$$

## Itération sur les valeurs : $k = 6$

0.59	0.73	0.85	+1.00
0.41		0.57	-1.00
0.21	0.31	0.43	0.19

$$r = 0$$

$$\gamma = 0.9$$

$$\text{bruit} = 0.2$$

## Itération sur les valeurs : $k = 7$

0.62	0.74	0.85	+1.00
0.50		0.57	-1.00
0.34	0.36	0.45	0.24

$$r = 0$$

$$\gamma = 0.9$$

$$\text{bruit} = 0.2$$

## Itération sur les valeurs : $k = 100$

0.64	0.74	0.85	+1.00
0.57		0.57	-1.00
0.49	0.43	0.48	0.28

$$r = 0$$

$$\gamma = 0.9$$

$$\text{bruit} = 0.2$$

## Limitations de Value Iteration

---

- la méthode est lente
  - la valeur du max change rarement
  - ⇒ pourtant c'est cela qui va aider à changer toutes les valeurs!
  - les valeurs peuvent mettre longtemps à converger exactement alors que la politique, elle, est déjà optimale depuis longtemps
- ⇒ on va essayer de travailler sur la politique.

Similairement à la fonction optimale, on peut définir deux fonctions de valeurs pour une politique fixée  $\pi$ .

### **Définition** (fonction de valeurs pour les états)

---

La *fonction de valeurs pour les états*  $v_\pi(s)$  d'un PDM est la valeur espérée de gains en partant dans l'état  $s$  et en poursuivant la politique  $\pi$ .

### **Définition** (fonction de valeurs pour les paires (état, action))

---

La *fonction de valeurs pour les paires état-actions*  $q_\pi(s,a)$  d'un PDM est la valeur espérée de gains en partant dans l'état  $s$ , en effectuant l'action  $a$  puis et en poursuivant la politique  $\pi$ .

## Equation de Bellman : pour les états

---

Dans l'état  $s$

on tire notre action avec la politique  $\pi(s)$

pour chaque action, on choisit l'action  $a$  avec la probabilité  $\pi(a|s)$ ,

on va effectuer l'action  $a$  puis continuer avec  $\pi$  dans l'état suivant

↪ on peut utiliser  $q_\pi$  !

$$\begin{aligned}v_\pi(s) &= \mathbb{E}_\pi [r_{t+1} + \gamma v_\pi(S_{t+1}) \mid S_t = s] \\ &= \sum_{a \in A} \pi(a|s) q_\pi(s, a)\end{aligned}$$

## Equation de Bellman : pour les actions

---

Similairement pour la fonction de valeurs pour les actions

- le modèle de récompense nous donne la récompense pour avoir effectué l'action  $a$  dans l'état  $s$ .
  - le modèle de transition nous donne l'état suivant  $s'$
- ⇒ dans ce nouvel état  $s'$ , on peut utiliser  $v_\pi$  !

$$\begin{aligned}q_\pi(s, a) &= \mathbb{E}_\pi [r_{t+1} + \gamma q_\pi(S_{t+1}, A_{t+1}) \mid S_t = s, A_t = a] \\ &= R_s^a + \gamma \sum_{s' \in \mathcal{S}} T_{ss'}^a v_\pi(s')\end{aligned}$$

On a établi :

$$v_{\pi}(s) = \sum_{a \in A} \pi(a|s) q_{\pi}(s, a)$$

$$q_{\pi}(s, a) = R_s^a + \gamma \sum_{s' \in S} T_{ss'}^a v_{\pi}(s')$$

Ensemble on obtient :

$$v_{\pi}(s) = \sum_{a \in A} \pi(a|s) \left( R_s^a + \gamma \sum_{s' \in S} T_{ss'}^a v_{\pi}(s') \right)$$

$$q_{\pi}(s, a) = R_s^a + \gamma \sum_{s' \in S} T_{ss'}^a \sum_{a' \in A} \pi(a'|s') q_{\pi}(s', a')$$

## Equation de Bellman

---

$$\begin{aligned}v_{\pi}(s) &= \sum_{a \in A} \pi(a|s) \left( R_s^a + \gamma \sum_{s' \in S} T_{ss'}^a v_{\pi}(s') \right) \\&= \sum_{a \in A} \pi(a|s) R_s^a + \gamma \sum_{a \in A} \sum_{s' \in S} \pi(a|s) T_{ss'}^a v_{\pi}(s') \\&= \sum_{a \in A} \pi(a|s) R_s^a + \gamma \sum_{s' \in S} \sum_{a \in A} \pi(a|s) T_{ss'}^a v_{\pi}(s') \\&= R_s^{\pi} + \gamma \sum_{s' \in S} T_{ss'}^{\pi} v_{\pi}(s')\end{aligned}$$

On peut donc écrire l'expression vectorielle

$$v_{\pi} = R^{\pi} + \gamma T^{\pi} v_{\pi}$$

On peut utiliser l'équation de Bellman comme une règle de mise à jour :

$$v_{k+1}(s) \leftarrow \sum_{a \in A} \pi(a | s) \left( R_s^a + \gamma \sum_{s' \in S} T_{ss'}^a v_k(s') \right)$$

### **Theorème**

---

La séquence  $\{v_k\}_{k \in \mathbb{N}}$  converge vers  $v^\pi$ .

Seconde idée : sans les max, les équations de Bellman forment un système linéaire à résoudre !

## Convergence plus rapide

---

Pour réaliser l'algorithme :

- avoir deux vecteur  $v_{old}$  et  $v_{new}$
  - calculer complètement  $v_{new}$  à partir de  $v_{old}$
- ➡ "full back up"

On peut aussi n'utiliser qu'un seul vecteur

- on remplace directement l'ancienne entrée par la nouvelle
  - le vecteur  $v$  contient à la fois des nouvelles et des anciennes valeurs
- ➡ on utilise les nouvelles valeurs au plus vite  
convergence toujours garantie et plus rapide  
l'ordre de mise à jour joue un rôle sur la vitesse de convergence.

*Critère d'arrêt de l'algorithme*

- garantie de convergence à la limite
- en pratique, on peut arrêter avant  
par exemple :  $\max_{s \in S} |v_{k+1}(s) - v_k(s)| < \epsilon$  pour une valeur de  $\epsilon$  donnée.

## Comment déterminer une bonne action à partir de $v$ ?

Supposons qu'on connaisse les valeurs optimales  $v^*(s)$

0.95	0.96	0.98	+1.00
0.94		0.89	-1.00
0.92	0.91	0.90	0.80

Comment devons-nous agir ?

On doit faire une étape d'expectimax !

$$\pi^*(s) = \arg \max_a \left[ R_s^a + \gamma \sum_{s'} T_{ss'}^a v^*(s') \right]$$

⇒ on peut appeler cette étape faire une extraction de politique.

## Comment déterminer une bonne action à partir de $q$ ?

Supposons qu'on connaisse les valeurs optimales  $q^*(s,a)$

$0.94$ $0.94$ $0.95$ $0.93$	$0.95$ $0.94$ $0.96$ $0.95$	$0.97$ $0.95$ $0.98$ $0.90$	$+1.00$
$0.94$ $0.93$ $0.93$ $0.92$	██████████	$0.76$ $0.89$ $-0.62$ $0.70$	$-1.00$
$0.92$ $0.91$ $0.90$ $0.91$	$0.90$ $0.91$ $0.89$ $0.90$	$0.87$ $0.90$ $0.81$ $0.88$	$-0.62$ $0.69$ $0.61$ $0.80$

Comment devons-nous agir ?

Trivial, on choisit la meilleure action ! (ou une des meilleurs actions).

$$\pi^*(s) = \arg \max_a q^*(s,a)$$

⇒ morale de l'histoire : les actions sont plus faciles à obtenir à partir de  $q$  qu'à partir de  $v$  !!

On peut essayer d'améliorer la politique en se comportant de manière "gloutonne"

Une fois  $v_\pi$  évaluée : on peut calculer  $q^\pi(s, a) = R_s^a + \gamma \sum_{s' \in S} T_{ss'}^a v_\pi(s')$

- si  $q^\pi(s, a) > v_\pi(s)$  : on a trouvé une amélioration!<sup>a</sup>
- ⇒ on peut regarder tous les états  $s \in S$  et mettre à jour la politique  
 $\pi'(s) = \arg \max_{a \in A} q_\pi(s, a)$

Si aucune amélioration n'est trouvée, on a donc  $v_\pi = v_{\pi'}$

$$\Rightarrow v_{\pi'} = \max_{a \in A} R_s^a + \gamma \sum_{s' \in S} T_{ss'}^a v_{\pi'}(s')$$

On reconnaît là l'équation de Bellman pour la fonction de valeurs *optimale*

On a donc trouvé  $v^* = v_{\pi'}$  !

---

a. il faut une petite démonstration sur ce point

L'idée est donc d'alterner

- 1- l'évaluation d'une politique
- 2- l'amélioration de la politique

*jusqu'à ce qu'on converge vers une politique qui sera la politique optimale.*

Pour les politiques déterministes, il y a un nombre fini de politiques, on va converger en un nombre fini d'itérations.

Variantes : quand arrêter l'évaluation ?

- convergence à un  $\epsilon$  près
- après  $k$  itérations ( $k$  a une petite valeur)
- pourquoi pas après chaque itération ?

## Comparaison

---

- Les deux méthodes calcule le même résultat : à la fin, on a les mêmes valeurs optimales ( $v^*$  et  $q^*$ )
- Itération sur les valeurs
  - la politique est implicite. A chaque itération, on met à jour les valeurs
  - si on travaille avec  $v$ , on doit utiliser l'extraction d'une politique pour obtenir la politique optimale.
- Iteration sur les politiques
  - plusieurs itérations pour mettre à jour les valeurs d'une politique fixe (mais pour chaque itération, on ne considère qu'une seule action, ce qui devrait être rapide).
  - on met à jour la politique, on doit comparer toutes les actions (peut être lent)
  - soit on améliore la politique, soit on a terminé!