

Agent Oriented Learning

Introduction apprentissage par renforcement - Résolutions

Stéphane Airiau

Université Paris-Dauphine

Definition (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

- 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

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

Cette équation est l'**équation de Bellman** pour la fonction de valeur optimale.

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

$$r = 0$$
$$\gamma = 0.9$$
$$\text{bruit} = 0.2$$

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

$$r = 0$$

$$\gamma = 0.9$$

$$\text{bruit} = 0.2$$

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

$$r = 0$$

$$\gamma = 0.9$$

$$\text{bruit} = 0.2$$

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.

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).

$$\pi^*(s) = \underset{a}{\operatorname{arg\,max}} q^*(s,a)$$

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

Equations de Bellman

En s'inspirant d'expectimax, on a écrit l'équation de Bellman

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

On pourrait définir cela plus formellement.

On définit la fonction de valeur pour la politique π , $v_{\pi} : S \mapsto \mathbb{R}$ telle que

$$v_{\pi}(s) = \mathbb{E}[G_t \mid S_t = s, \pi]$$

où $G_t = r_{t+1} + \gamma r_{t+2} + \gamma^2 r_{t+3} + \dots = \sum_{k=0}^{\infty} \gamma^k r_{t+k+1}$

$v_{\pi}(s)$ est la valeur à *long terme* de se trouver dans l'état s puis d'utiliser la politique π pour choisir ses actions.

On peut montrer que v_{π} satisfait une équation de Bellman.

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

Equations de Bellman

Ensuite, on pourrait définir $v^*(s) = \max_{\pi} v_{\pi}(s)$

En on pourrait montrer que v^* satisfait l'équation de Bellman

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

On peut montrer que :

- cette équation admet une unique solution v^*
- on peut définir une politique optimale comme étant une politique π^* telle que $v_{\pi^*} = v^*$
- il peut y avoir plusieurs politiques optimales
- au moins une politique optimale est déterministe :

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

Autre stratégie de résolutions : améliorer une politique petit à petit

On peut partir d'une politique arbitraire π et essayer de la modifier pour améliorer les performances.

$$\pi_0 \xrightarrow{\text{évalue}} v_{\pi_0} \xrightarrow{\text{améliore}} \pi_1 \xrightarrow{\text{évalue}} v_{\pi_1} \rightarrow \dots \rightarrow \pi_* \xrightarrow{\text{évalue}} v_{\pi_*}$$

On va améliorer la politique en se comportant de manière "gloutonne"

Une fois v_π 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!^a

⇒ 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 $v_\pi = v_{\pi'}$

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

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 ϵ près
- après k itérations (k a une petite valeur)
- pourquoi pas après chaque itération ?

Comparaison

- Les deux méthodes calculent 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.
- Itération 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!

Résolution à l'aide de méthodes Monte Carlo pour des PDMs épisodiques

Pour les deux algorithmes vus précédemment ("iteration sur les valeurs" et "iteration sur les politiques"), on devait connaître :

- le modèle de transition $T_{ss'}^a$
- le modèle de récompense R_s^a

Aujourd'hui, on va voir des méthodes qui **ne** nécessitent **pas** la connaissance des ces modèles.

- ➡ seule l'expérience va guider le choix
- ➡ véritablement de l'apprentissage

Environnement épisodique

On va se placer seulement dans des PDMs épisodique :

- chaque épisode doit se terminer
- on va apprendre d'un épisode en entier
- un épisode : une partie de black jack

1. Méthodes Monte Carlo

- Evaluation d'une politique
- Estimation de la valeur des actions
- Contrôle par Monte Carlo ("on policy" et "off policy")

Méthode Monte Carlo : Evaluation d'une politique π

- apprendre v_π à partir des épisodes en suivant une politique π
- On veut apprendre la valeur *à long terme*
Pour un épisode qui se termine à l'itération k , on a

$$G_t = R_{t+1} + \gamma R_{t+2} + \dots + \gamma^{k-t} R_{k+t}$$

- $v_\pi(s)$ est la valeur de passer par l'état s en utilisant la politique π :


$$v_\pi(s) = \mathbb{E}_\pi[G_t | S_t = s]$$

- on va utiliser l'expérience de l'agent pour estimer $v_\pi(s)$ pour chaque état s .
- Attention, dans un épisode, on peut passer plusieurs fois par le même état !

Méthode Monte Carlo : Evaluation d'une politique

algorithme première visite

Exécute *un* épisode



fin de l'épisode

Une fois l'épisode terminé
je fais les mises à jour

$$G_0 = r_1 + \gamma r_2 + \gamma^2 r_3 + \gamma^3 r_4$$

$$G_1 = r_2 + \gamma r_3 + \gamma^2 r_4$$

$$G_2 = r_3 + \gamma r_4$$

$$G_3 = r_4$$

→ m.à.j $v(S_0)$ avec G_0


$v(S_1)$ " G_1 si $S_1 \neq S_0$

$v(S_2)$ " G_2 si $S_2 \neq S_1$ et $S_2 \neq S_0$

$v(S_3)$ " G_3 si $S_3 \neq S_2$, $S_3 \neq S_1$, $S_3 \neq S_0$

Méthode Monte Carlo : Evaluation d'une politique

algorithme première visite



Algorithme "première visite"

```
1  $v \in \mathbb{R}^{|S|}$ ,  $count \in \mathbb{N}^{|S|}$ ,  $Acc \in \mathbb{R}^{|S|}$ 
2 initialise  $v(s) = 0$  pour chaque état  $s \in S$ 
3 initialise  $count(s) = 0$  pour chaque état  $s \in S$ 
4 initialise  $Acc(s) = 0$  pour chaque état  $s \in S$ 
5
6 Répète éternellement
7   Simule un épisode en suivant la politique  $\pi$ 
8   Pour chaque transition  $t$  de l'épisode, on calcule  $G_t$ 
9   Pour chaque état  $s$  qui apparait dans l'épisode
10     Pour la première itération  $t$  où  $s$  est visité dans l'épisode
11        $Acc(s) \leftarrow Acc(s) + G_t$ 
12        $count(s) \leftarrow count(s) + 1$ 
13        $v(s) \leftarrow \frac{Acc(s)}{count(s)}$ 
```

chaque valeur de G_t est un échantillon tiré de manière indépendante et identiquement distribué, avec une variance finie

⇒ avec la loi des grands nombres, on a

$$\lim_{count(s) \rightarrow \infty} v(s) = v_{\pi}(s)$$

Algorithme "chaque visite"

```
1   $v \in \mathbb{R}^{|S|}$ ,  $count \in \mathbb{N}^{|S|}$ ,  $Acc \in \mathbb{R}^{|S|}$ 
2  initialise  $v(s) = 0$  pour chaque état  $s \in S$ 
3  initialise  $count(s) = 0$  pour chaque état  $s \in S$ 
4  initialise  $Acc(s) = 0$  pour chaque état  $s \in S$ 
5
6  Répète éternellement
7      Simule un épisode en suivant la politique  $\pi$ 
8      Pour chaque transition  $t$  de l'épisode, on calcule  $G_t$ 
9      Pour chaque itération  $t$  qui visite l'état  $s$ 
10          $Acc(s) \leftarrow Acc(s) + G_t$ 
11          $count(s) \leftarrow count(s) + 1$ 
12          $v(s) \leftarrow \frac{Acc(s)}{count(s)}$ 
```

Ici, chacun des échantillons n'est pas forcément indépendant des autres. Mais on a quand même convergence vers $v_\pi(s)$.

(Singh & Sutton, 1996)

si un état s se répète, le fait de retomber dans l'état s n'est sûrement pas un hasard, et donc il y a une corrélation entre le premier passage et le second...

Très différent de l'utilisation de la programmation dynamique

- toutes les transitions possibles / seulement les transitions de l'épisode
- une seule transition / toutes les transitions de l'épisode
- l'estimation de chaque état est fait de manière indépendante / l'estimation d'un état dépend de l'estimation des autres états
- ➡ l'estimation est indépendante du nombre d'états $|S|$.
- ➡ on peut partir d'un état et faire des simulations pour apprendre ces états sans se soucier des autres

- Si on n'a pas le modèle $T_{ss'}^a$, on a beau avoir $v_\pi(s)$, on ne peut pas déduire l'action optimale!

En effet, pour cela on a *besoin* de faire le calcul :

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

- Rappel $q_\pi(s, a)$ estime la valeur à long terme de prendre l'action a puis de suivre la politique π .
- au lieu d'estimer v_π avec notre algorithme de Monte Carlo, on va estimer q_π
 - a priori même stratégie "première visite" et "chaque visite" possible
- attention, maintenant il faut tenir un compte sur chaque paire (action, état)
- il faudra faire attention à avoir suffisamment d'observations pour chaque paire!

Algorithme version "première visite"

```
1  $q \in \mathbb{R}^{|S| \times |A|}$ ,  $count \in \mathbb{N}^{|S| \times |A|}$ ,  $Acc \in \mathbb{R}^{|S| \times |A|}$ 
2 initialise  $q(s,a) = 0$  pour chaque état  $s \in S$  et chaque action  $a \in A$ 
3 initialise  $count(s) = 0$  pour chaque état  $s \in S$  et chaque action  $a \in A$ 
4 initialise  $Acc(s) = 0$  pour chaque état  $s \in S$  et chaque action  $a \in A$ 
5
6 Répète éternellement
7   Simule un épisode en suivant la politique  $\pi$ 
8   Pour chaque transition  $t$  de l'épisode, on calcule  $G_t$ 
9   Pour chaque état  $s$  qui apparait dans l'épisode
10     Pour la première itération  $t$  où  $s$  est visité dans l'épisode
11        $Acc(s,a) \leftarrow Acc(s,a) + G_t$ 
12        $count(s,a) \leftarrow count(s) + 1$ 
13        $q(s,a) \leftarrow \frac{Acc(s,a)}{count(s,a)}$ 
```

chaque valeur de G_t est un échantillon tiré de manière indépendante et identiquement distribué, avec une variance finie

⇒ avec la loi des grands nombres, on a

$$\lim_{count(s,a) \rightarrow \infty} q(s,a) = q_{\pi}(s,a)$$

Evaluation de la valeur des actions

- petit problème : si π est déterministe, on n'a pas la valeur de toutes les paires (état, action)
on aura seulement des valeurs pour les paires $s, \pi(s)$

- petit problème : si π est déterministe, on n'a pas la valeur de toutes les paires (état, action)
on aura seulement des valeurs pour les paires $s, \pi(s)$
- une stratégie : "exploring starts"
on tire au hasard une paire (s_0, a_0) pour l'état initial et on utilise "première visite"
⇒ on utilise la loi des grands nombres pour estimer $q_\pi(s_0, a_0)$

- petit problème : si π est déterministe, on n'a pas la valeur de toutes les paires (état, action)
on aura seulement des valeurs pour les paires $s, \pi(s)$
- une stratégie : "exploring starts"
on tire au hasard une paire (s_0, a_0) pour l'état initial et on utilise "première visite"
⇒ on utilise la loi des grands nombres pour estimer $q_{\pi}(s_0, a_0)$
- Evidemment, ceci est problématique pour des interactions avec un environnement réel (on ne peut pas forcément choisir l'état initial!!)
- Supposons pour le moment qu'on puisse faire cela
on verra comment le contourner plus tard.

- petit problème : si π est déterministe, on n'a pas la valeur de toutes les paires (état, action)
on aura seulement des valeurs pour les paires $s, \pi(s)$
- une stratégie : "exploring starts"
on tire au hasard une paire (s_0, a_0) pour l'état initial et on utilise "première visite"
⇒ on utilise la loi des grands nombres pour estimer $q_\pi(s_0, a_0)$
- Evidemment, ceci est problématique pour des interactions avec un environnement réel (on ne peut pas forcément choisir l'état initial!!)
- Supposons pour le moment qu'on puisse faire cela
on verra comment le contourner plus tard.
- On devrait avoir une bonne estimation de $q_\pi(s, a)$ pour chaque paire (s, a) .

Même idée que pour itération des politiques :
une approximation de la fonction de valeurs optimale et une approximation de la politique optimale

$$\pi_0 \xrightarrow{\text{évalue}} q_{\pi_0} \xrightarrow{\text{améliore}} \pi_1 \xrightarrow{\text{évalue}} q_{\pi_1} \rightarrow \dots \rightarrow \pi_{\star} \xrightarrow{\text{évalue}} q_{\pi_{\star}}$$

- utilisation d'une infinité d'épisode pour estimer $q_{\pi}(s, a)$ avec "exploring starts"
- améliore de façon gloutonne la politique π comme dans itération des politiques : $\pi_{k+1}(s) = \operatorname{argmax}_a q_{\pi_k}(s, a)$
- ➡ même garantie de convergence que pour itération des politiques

peut-on utiliser moins d'épisodes pour évaluer une politique ?

On reprend l'idée de l'algorithme itération sur les valeurs :

1. Utilisation d'une convergence à ϵ près pour estimer $q_\pi(s,a)$
on peut calculer des bornes pour être sûr de faire suffisamment d'itérations
⇒ on peut garantir la convergence, mais sûrement beaucoup trop d'itérations pour être une solution en pratique
2. plus extrême : utiliser seulement un épisode avant de faire une amélioration.
⇒ mais pour le moment, on n'a pas de garantie de convergence !
cependant, on a du mal à se convaincre que cela ne va pas converger !

Evaluation de la politique optimale : "Monte Carlo Exploring Starts"

```
1   $q \in \mathbb{R}^{|S| \times |A|}$ 
2   $count \in \mathbb{N}^{|S| \times |A|}$ 
3   $Acc \in \mathbb{R}^{|S| \times |A|}$ 
4  initialise  $v(s,a) = 0$  pour chaque état  $s \in S$  et action  $a \in A$ 
5  initialise  $count(s,a) = 0$  pour chaque état  $s \in S$  et action  $a \in A$ 
6  initialise  $Acc(s,a) = 0$  pour chaque état  $s \in S$  et action  $a \in A$ 
7
8  Répète éternellement
9      Tire aléatoirement une paire  $(s_0, a_0) \in S \times A$ 
10     Simule un épisode en suivant la politique  $\pi$  en partant de  $(s_0, a_0)$ 
11     Pour chaque paire  $(s,a)$  qui est visitée dans l'épisode
12         Si la première occurrence de  $(s,a)$  est à l'instant  $t$ 
12              $Acc(s,a) \leftarrow Acc(s,a) + G_t$ 
13              $count(s,a) \leftarrow count(s,a) + 1$ 
14              $q(s,a) \leftarrow \frac{Acc(s,a)}{count(s,a)}$ 
15         Pour chaque état  $s$  dans l'épisode
16              $\pi(s) \leftarrow \underset{a \in A}{\arg \max} q(s,a)$ 
```

pas encore de démonstration que la convergence soit garantie!!!
(mais l'hypothèse exploring starts est trop forte!)

Eviter l'astuce "exploring starts"

Avec les méthodes Monte Carlo, on a fait deux hypothèses jusqu'ici :

1. on travaille dans un PDM épisodique
2. on peut choisir l'état initial au hasard pour garantir de visiter toutes les paires $(s,a) \in S \times A$

On veut trouver une technique pour éviter l'hypothèse "exploring starts"

- Comme pour le problème des bandits, il va falloir **explorer**
- soit on va essayer d'améliorer la politique qu'on utilise pour générer les données : approche "on policy"
- soit on va utiliser une politique pour générer les données, et mettre à jour une autre politique (qui n'est pas utilisée) : approche "off policy"

"on-policy" Monte Carlo

- estime et améliore une politique tout en l'utilisant
- utiliser une politique stochastique avec des probabilités strictement positives
 $\pi(s,a) > 0$ "politique soft"
- ➡ graduellement mettre à jour cette politique vers une politique déterministique (et optimale!)
- ajouter de l'**exploration** aléatoire

ex : ϵ -greedy {

- utiliser $\arg \max_{a \in A} q(s,a)$ avec une probabilité $1 - \epsilon$
- tirer une action avec une probabilité uniforme avec une probabilité ϵ

Evaluation de la politique optimale : "on policy Monte Carlo"

version première visite

- 1 $q: S \times A \rightarrow \mathbb{R}$ initialise $q(s,a) = 0 \forall s \in S$ et $\forall a \in A$
- 2 $count: S \times A \rightarrow \mathbb{N}$ initialise $count(s,a) = 0 \forall s \in S$ et $\forall a \in A$
- 3 $Acc: S \times A \rightarrow \mathbb{R}$ initialise $Acc(s,a) = 0 \forall s \in S$ et $\forall a \in A$
- 3 π une politique soft (par exemple uniforme)
- 7
- 8 Répète éternellement
- 10 Simule un épisode en entier en suivant la politique π
- 10 Compute G_t pour chaque transition de l'épisode
- 11 Pour **chaque paire** (s,a) qui est visitée dans l'épisode
- 12 Si la première occurrence de (s,a) est à l'instant t
- 12 $Acc(s,a) \leftarrow Acc(s,a) + G_t$
- 13 $count(s,a) \leftarrow count(s,a) + 1$
- 14 $q(s,a) \leftarrow \frac{Acc(s,a)}{count(s,a)}$
- 15 Pour chaque état s dans l'épisode
- 16 $a^* \leftarrow \arg \max_{a \in A} q(s,a)$ (départage arbitraire des ex-æquos)
- 15 Pour chaque action a
- 16
$$\pi(s,a) \leftarrow \begin{cases} 1 - \epsilon + \frac{\epsilon}{|A|} & \text{if } a = a^* \\ \frac{\epsilon}{|A|} & \text{if } a \neq a^* \end{cases}$$

Vérification de l'amélioration

On nomme π' la politique ϵ -greedy.

Pour n'importe quelle politique π , on a $\sum_{a \in A} \left(\pi(s, a) - \frac{\epsilon}{|A|} \right) = 1 - \epsilon$

$$\begin{aligned} q(s, \pi'(s)) &= \sum_{a \in A} \pi'(s, a) q(s, a) \\ &= \frac{\epsilon}{|A|} \sum_{a \in A} q(s, a) + (1 - \epsilon) \max_{a \in A} q(s, a) \\ &= \frac{\epsilon}{|A|} \sum_{a \in A} q(s, a) + (1 - \epsilon) \sum_{a \in A} \frac{\pi(s, a) - \frac{\epsilon}{|A|}}{1 - \epsilon} \max_{a \in A} q(s, a) \\ &\geq \frac{\epsilon}{|A|} \sum_{a \in A} q(s, a) + (1 - \epsilon) \sum_{a \in A} \frac{\pi(s, a) - \frac{\epsilon}{|A|}}{1 - \epsilon} q(s, a) \\ &\geq \frac{\epsilon}{|A|} \sum_{a \in A} q(s, a) + \sum_{a \in A} \pi(s, a) q(s, a) - \frac{\epsilon}{|A|} \sum_{a \in A} q(s, a) \\ &\geq \sum_{a \in A} \pi(s, a) q(s, a) = q_{\pi}(s, a) \text{ On a bien une amélioration! } \square \end{aligned}$$

Vérification de la convergence

Il reste à démontrer la convergence vers une soft politique optimale.

Il faut montrer qu'on a une égalité quand π (où π') sont optimales sur les soft policies (i.e. aucune autre politique "soft" ne peut les dominer).

On considère un environnement ϵ - E dérivé de notre environnement E : si on exécute une action a dans ϵ - E , le résultat est celui de prendre une action de manière uniforme avec une probabilité ϵ dans E et de d'exécuter l'action a avec une probabilité $1 - \epsilon$ dans E .

Soit \tilde{v}^* et \tilde{q}^* les fonctions de valeurs optimales dans ϵ - E .

Une politique π est optimale dans E parmi les politiques softs ssi $v_\pi = \tilde{v}^*$

D'après la définition de \tilde{v}^* , ce doit être l'*unique* solution de :

$$\begin{aligned}\tilde{v}^*(s) &= (1 - \epsilon) \max_a \tilde{q}^*(s, a) + \frac{\epsilon}{|A|} \sum_{a \in A} \tilde{q}^*(s, a) \\ &= (1 - \epsilon) \max_a \sum_{s', r} p(s', r | s, a) [r + \gamma \tilde{v}^*(s')] \\ &\quad + \frac{\epsilon}{|A|} \sum_{a \in A} \sum_{s', r} p(s', r | s, a) [r + \gamma \tilde{v}^*(s')]\end{aligned}$$

Quand l'égalité est obtenue et qu'on ne peut pas améliorer π , on a :

$$\begin{aligned}v_\pi(s) &= (1 - \epsilon) \max_a q_\pi(s, a) + \frac{\epsilon}{|A|} \sum_{a \in A} q_\pi(s, a) \\ &= (1 - \epsilon) \max_a \sum_{s', r} p(s', r | s, a) [r + \gamma v_\pi(s')] \\ &\quad + \frac{\epsilon}{|A|} \sum_{a \in A} \sum_{s', r} p(s', r | s, a) [r + \gamma v_\pi(s')]\end{aligned}$$

Comme \tilde{v}^* est l'*unique* solution, on doit avoir $\tilde{v}^* = v_\pi$

- On parvient à trouver la meilleure politique parmi les politique ϵ -soft
- Sans avoir besoin de faire l'hypothèse (souvent peu réaliste) "exploring starts".
- ➡ apprentissage d'une politique presque optimale qui continue à explorer.

- une autre stratégie est d'avoir deux politiques :
 - une pour explorer et générer des données
 - l'autre que l'on optimise
 - mais pour notre cours, on ne va pas étudier ces autres algorithmes.

Conclusions

Dans des domaines où on peut répéter beaucoup d'épisodes

- on est capable d'évaluer une politique
 - on est capable de trouver une politique optimale
- ⇒ on n'a plus besoin de connaître les modèles de transitions T et de récompenses R
- dans beaucoup de situations, il est facile de simuler des épisodes.
 - si on a besoin d'étudier des états particuliers et qu'on peut les simuler ⇒ on peut simplement faire les calculs pour ces états.
 - ces méthodes n'effectuent pas de "bootstrap"