


CHAPITRE 4 (Suite)




Apprentissage par Renforcement

A Goal Directed Learning from Interaction

Rappel

Recherche par un **agent autonome** d'une **politique** de décision **optimale**. Ceci via des **interactions** de genre « **essai-erreur** » avec son **environnement** suite desquelles il est **récompensé** ou **pénalisé**. L'agent apprend la meilleure politique, qui est la séquence des actions qui **maximisent sa récompense totale**



$$\square \pi: S \times A \rightarrow [0,1]$$

$$(s, a) \rightarrow \pi(s, a) = \wp[A_t = a | S_t = s]$$

$$\square p(s'|s, a) = \Pr\{S_{t+1} = s' | S_t = s, A_t = a\}$$

$$\square r(s, a, s') = E[R_{t+1} | S_t = s, A_t = a, S_{t+1} = s']$$

□ $V_\pi: S \rightarrow \mathbb{R}$ (un vecteur avec une entrée par état)

$$V_\pi(s) = E_\pi [G_t | S_t = s] = E_\pi [\sum_{k=0}^{\infty} \gamma^k R_{t+k+1} | S_t = s]$$

$$V_\pi(s) = E_\pi [G_t | S_t = s] = E_\pi \left[\sum_{k=0}^{\infty} \gamma^k R_{t+k+1} \middle| S_t = s \right]$$

□ $q_\pi: S \times A \rightarrow \mathbb{R}$ (une matrice avec une entrée par état/action)

$$q_\pi(s, a) = E_\pi [G_t | S_t = s, A_t = a] = E_\pi \left[\sum_{k=0}^{\infty} \gamma^k R_{t+k+1} \middle| S_t = s, A_t = a \right]$$

□ Équations de Bellman

$$V_\pi(s) = \sum_a \pi(a|s) \sum_{s',r} p(s',r|s,a) [R_{t+1} + \gamma V_\pi(s')]$$

□ À savoir :

$$V_\pi(s) = \sum_a \pi(a|s) q_\pi(s, a)$$

Exemple

- Objectif: atteindre le coin supérieur à gauche ou le coin inférieur à droite.
- L'état de l'agent correspond à sa position dans la grille.
- $A = \{haut, bas, gauche, droite\}$
- Politique de l'agent: $\pi(a|s) = 0.25 \forall s \forall a$
- La fonction de transition est déterministe. Si l'action fait sortir l'agent de la grille alors considérer que sa position reste inchangée.
- $r = -1$ pour chaque transition
- $\gamma = 1$

Fonction de valeur $V_\pi(s)$

0.0	A	-20.	-22.
-14.	-18.	-20.	B
C	-20.	-18.	-14.
-22.	-20.	D	0.0

Travail demandé

Calculer : $V_\pi(A) = ?$

$q_\pi(B, bas) = ?$

Algorithmes D'apprentissage Par Renforcement

- **Objectif?** approximer la politique de décision optimale
- Si on connaît le **modèle de l'environnement** (*fonction de transition & de récompense*) on peut appliquer la méthode de la **programmation dynamique**. (*model-based*)
- Pratiquement, ce modèle est souvent inconnu (*model-free*) :
 - Méthodes de Monte-Carlo (Sampling)
 - Every-Visit MC
 - First-Visit MC
 - Temporel Difference Learning (Bootstraping)
 - Q-learning
 - SARSA

3. MÉTHODES DE MONTE-CARLO

- ❑ Fonction de valeur:

$$V_\pi(s) = E_\pi[G_t | s_t = s]$$

$$V_\pi(s) = \sum_a \pi(a|s) \sum_{s',r} p(s',r|s,a) [R_{t+1} + \gamma V_\pi(s')]$$

- ❑ On veut **Apprendre** (ou Estimer) la fonction de valeur V_π d'une politique π .

- ❑ Comment ?

- ✓ On dispose d'un grand nombre trajectoires issues de chaque état s (sorte d'échantillon de transitions) de type « état , action, renforcement, ... » obtenues par ***interaction directe*** ou par ***Simulation***:

$$S_1, A_1, R_2, S_2, \dots, S_k$$

✓ Estimer $V(s)$ en **moyennant** les retours observés sur chacune de ces trajectoires:

- $Somme(s) \leftarrow Somme(s) + G_t$
- $N(s) \leftarrow N(s) + 1$
- $V(s) \leftarrow Somme(s)/N(s)$

Loi des grands nombres

La valeur estimée (moyenne empirique) associée à chaque état converge vers la valeur exacte (espérance) de l'état pour la politique qu'il suit:

$$V(s) \rightarrow V_\pi(s) \text{ lorsque } N(s) \rightarrow \infty$$

Exemple

```
Somme(s) ← Somme(s) + Gt
```

```
N(s) ← N(s) + 1
```

```
V(s) ← Somme(s)/N(s)
```

□ Soit un MDP avec deux états P et Q. On donne les Deux trajectoires suivantes:

- $P, +3, P, +2, Q, -4, \quad P, \quad +4, Q, -3$
- $Q, -2, \quad P, \quad +3, Q, -3$

□ Comment procéder ?

1. Mise à jour de la valeur d'un état **plusieurs fois** le long d'une même trajectoire.
(Estimation Biaisée)
2. **Solution:** Ne mettre à jour la valeur d'un état que lors de sa **première rencontre** le long de la trajectoire observée.

□ Calculer:

- $V(P) = ? \quad V(Q) = ?$

Estimation de la fonctions d'utilité liée aux actions $q_\pi(s, a)$

- Quand la *fonction de transition est inconnu*, il est plus utile d'estimer $q_\pi(s, a)$ que d'estimer $V_\pi(s)$.
- Nous allons garder les mêmes idées de :
 - *First-Visit MC* : considérer seulement la première occurrence du couple (s,a)
 - *Every-Visit MC* : considérer toutes les occurrences...
- Afin d'évaluer toutes les actions pour chaque état , il faut *maintenir l'exploration* : utiliser plutôt des ***politiques stochastiques*** avec une probabilité non nulle de choisir chacune des actions :


$$\pi(a|s) > 0 \quad \forall s \in S \quad \forall a \in A(s)$$

Politiques stochastiques

- **Politique ϵ – soft** : toute politique dont la probabilité du choix de chaque action **est au moins** $\frac{\epsilon}{|\mathcal{A}|}$


$$\text{moins } \frac{\epsilon}{|\mathcal{A}|}$$

- **Uniform Random policy:** chaque action $\frac{\epsilon}{|\mathcal{A}|}$




- **Politique ϵ – greedy**: souvent choisit l'action gloutonne et occasionnellement une des actions non-gloutonnes:

$$\pi(s, a) \leftarrow \begin{cases} 1 - \epsilon + \frac{\epsilon}{|A(s)|} & \text{if } a = a^* \\ \frac{\epsilon}{|A(s)|} & \text{if } a \neq a^* \end{cases}$$



De l'estimation au contrôle

- On cherche à trouver la politique optimale.
- On va faire alterner , jusqu'à convergence: Evaluation et Amélioration .



- commencer par une politique arbitraire π_0
- Evaluer cette politique c'est-à-dire estimer $q_{\pi_0}(s, a)$ comme déjà vu
- Améliorer π_0 c'est-à-dire construire une politique π_1 comme la politique gloutonne respectivement à q_{π_0}
- Ce cycle est répété jusqu'à convergence vers la politique optimale:

$$\pi_0 \xrightarrow{E} q_{\pi_0} \xrightarrow{A} \pi_1 \xrightarrow{E} q_{\pi_1} \xrightarrow{A} \dots \xrightarrow{A} \pi_* \xrightarrow{E} q_{\pi_*}$$

Remarque

$$G_t = R_{t+1} + \gamma R_{t+2} + \gamma^2 R_{t+3} + \gamma^3 R_{t+4} + \dots$$

$$G_t = R_{t+1} + \gamma(\color{red}{R_{t+2} + \gamma^1 R_{t+3} + \gamma^2 R_{t+4} + \dots})$$

$$G_t = R_{t+1} + \gamma G_{t+1}$$

Exemple

Considérer $\gamma = 0.5$ et $T = 5$. La séquence des récompenses suivantes est reçues: $R_1 = -1$ $R_2 = 2$ $R_3 = 6$ $R_4 = 3$ $R_5 = 2$.

Trouver: G_5, G_4, \dots, G_0 .

On-policy first-visit MC control (for ε -soft policies), estimates $\pi \approx \pi_*$

Initialize, for all $s \in \mathcal{S}$, $a \in \mathcal{A}(s)$:

$$Q(s, a) \leftarrow \text{arbitrary}$$

$$Returns(s, a) \leftarrow \text{empty list}$$

$$\pi(a|s) \leftarrow \text{an arbitrary } \varepsilon\text{-soft policy}$$

Repeat forever:

(a) Generate an episode using π

(b) For each pair s, a appearing in the episode:

$$G \leftarrow \text{the return that follows the first occurrence of } s, a$$

Append G to $Returns(s, a)$

$$Q(s, a) \leftarrow \text{average}(Returns(s, a))$$

(c) For each s in the episode:

$$A^* \leftarrow \arg \max_a Q(s, a)$$

For all $a \in \mathcal{A}(s)$:

$$\pi(a|s) \leftarrow \begin{cases} 1 - \varepsilon + \varepsilon/|\mathcal{A}(s)| & \text{if } a = A^* \\ \varepsilon/|\mathcal{A}(s)| & \text{if } a \neq A^* \end{cases}$$

Prédiction incrémentale Monte Carlo

- On dispose d'un ensemble d'observations: x_1, x_2, \dots, x_k et on veut calculer la moyenne:

$$\mu_k = \frac{1}{k} \sum_{j=1}^k x_j$$

- Mise à jour incrémentale :

$$\mu_k \leftarrow \mu_k + \frac{1}{k} (x_k - \mu_k)$$

- Prédiction de la fonction de valeur dans MC

$$V(s_t) \leftarrow V(s_t) + \frac{\mathbf{1}}{N(\mathbf{s}_t)} (G_t - V(s_t))$$

- Définition plus générale ($0 < \alpha < 1$):

$$V(s_t) \leftarrow V(s_t) + \alpha (G_t - V(s_t))$$

4. Méthodes De Différence Temporelle

Prédiction TD(0) (one-step TD)

$$V(s_t) \leftarrow V(s_t) + \alpha(G_t - V(s_t))$$

Idée des méthodes TD: Ne pas attendre la fin de l'épisode mais faire la mise à jour à chaque étape t :

1. **Sampling** : apprendre à base de l'expérience " R_{t+1} "
2. **Bootstrapping** : MAJ des estimations basées sur d'autres estimations déjà acquises " $V(s_{t+1})$ "

$$V(s_t) \leftarrow V(s_t) + \alpha(R_{t+1} + \gamma V(s_{t+1}) - V(s_t))$$

□ Erreur TD converge itérativement à zéro:

$$\delta_t = R_{t+1} + \gamma V(s_{t+1}) - V(s_t)$$

Tabular TD(0) for estimating v_π

Input: the policy π to be evaluated

Algorithm parameter: step size $\alpha \in (0, 1]$

Initialize $V(s)$, for all $s \in \mathcal{S}^+$, arbitrarily except that $V(\text{terminal}) = 0$

Loop for each episode:

 Initialize S

 Loop for each step of episode:


$A \leftarrow$ action given by π for S

 Take action A , observe R, S'

$V(S) \leftarrow V(S) + \alpha [R + \gamma V(S') - V(S)]$


$S \leftarrow S'$

 until S is terminal



SARSA : Contrôle TD sur politique

- SARSA: le nom provient des 4 éléments utilisés dans la règle de Mise-jour :



- SARSA comme c'est un algorithme de contrôle cherche à estimer Q_π . Alors

$$V(s_t) \leftarrow V(s_t) + \alpha(R_{t+1} + \gamma V(s_{t+1}) - V(s_t))$$

Devient:

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

- SARSA est Sur-Politique : estimer Q_π et π c'est la politique de comportement.
- GPI (evaluation & amélioration)
- Exploration (politique ε – greedy)

Sarsa (on-policy TD control) for estimating $Q \approx q_*$

Algorithm parameters: step size $\alpha \in (0, 1]$, small $\varepsilon > 0$

Initialize $Q(s, a)$, for all $s \in \mathcal{S}^+, a \in \mathcal{A}(s)$, arbitrarily except that $Q(\text{terminal}, \cdot) = 0$

Loop for each episode:

 Initialize S

 Choose A from S using policy derived from Q (e.g., ε -greedy)


 Loop for each step of episode:

 Take action A , observe R, S'

 Choose A' from S' using policy derived from Q (e.g., ε -greedy)

$$Q(S, A) \leftarrow Q(S, A) + \alpha [R + \gamma Q(S', A') - Q(S, A)]$$
$$S \leftarrow S'; A \leftarrow A';$$

 until S is terminal



Q-Learning : Contrôle TD hors politique

- Dans SARSA:

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

- Dans Q-Learning:

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha \left(R_{t+1} + \gamma \max_a Q(s_{t+1}, a) - Q(s_t, a_t) \right)$$

L'action a utilisée dans la mise à jour n'est pas forcément celle qui sera prise dans l'état suivant S_{t+1} .

Q -learning (off-policy TD control) for estimating $\pi \approx \pi_*$

Algorithm parameters: step size $\alpha \in (0, 1]$, small $\varepsilon > 0$

Initialize $Q(s, a)$, for all $s \in \mathcal{S}^+, a \in \mathcal{A}(s)$, arbitrarily except that $Q(\text{terminal}, \cdot) = 0$

Loop for each episode:

 Initialize S

 Loop for each step of episode:

 Choose A from S using policy derived from Q (e.g., ε -greedy)

 Take action A , observe R, S'

$$Q(S, A) \leftarrow Q(S, A) + \alpha [R + \gamma \max_a Q(S', a) - Q(S, A)]$$

$$S \leftarrow S'$$

 until S is terminal