

Apprentissage par renforcement

Cours 4: méthodes de différences temporelles

Stéphane Airiau

Université Paris Dauphine

Temporal-difference Learning

Combine des idées de
la programmation dynamique (DP)
avec
les méthodes de Monte Carlo (MC)

Méthodes "Temporal-difference"

- elles apprennent directement avec l'expérience (comme MC)
- elles sont sans modèle : pas besoin de connaître les modèles de transition ou de récompenses (comme MC)
- elles peuvent apprendre d'épisodes incomplets (comme PD)
- elles utilisent des estimations pour mettre à jour son estimation (comme DP)

On veut estimer la valeur des états pour une politique fixe π .

$$\begin{aligned}v_{\pi}(s) &= \mathbb{E}_{\pi}[G_t \mid s_t = s] \\ &= \mathbb{E}_{\pi}[r_{t+1} + \gamma \sum_{k=0}^{\infty} \gamma^k r_{t+k+2} \mid s_t = s] \\ &= \mathbb{E}_{\pi}[r_{t+1} + \gamma v_{\pi}(s_{t+1}) \mid s_t = s]\end{aligned}$$

- Méthode Monte Carlo "chaque visite"

On veut estimer la valeur des états pour une politique fixe π .

$$\begin{aligned}v_{\pi}(s) &= \mathbb{E}_{\pi}[G_t \mid s_t = s] \\ &= \mathbb{E}_{\pi}[r_{t+1} + \gamma \sum_{k=0}^{\infty} \gamma^k r_{t+k+2} \mid s_t = s] \\ &= \mathbb{E}_{\pi}[r_{t+1} + \gamma v_{\pi}(s_{t+1}) \mid s_t = s]\end{aligned}$$

- Méthode Monte Carlo "chaque visite"
 - estimation à l'aide du véritable gain G_t obtenu lors d'un épisode

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

On veut estimer la valeur des états pour une politique fixe π .

$$\begin{aligned}v_{\pi}(s) &= \mathbb{E}_{\pi}[G_t \mid s_t = s] \\ &= \mathbb{E}_{\pi}[r_{t+1} + \gamma \sum_{k=0}^{\infty} \gamma^k r_{t+k+2} \mid s_t = s] \\ &= \mathbb{E}_{\pi}[r_{t+1} + \gamma v_{\pi}(s_{t+1}) \mid s_t = s]\end{aligned}$$

- Méthode Monte Carlo "chaque visite"

- estimation à l'aide du véritable gain G_t obtenu lors d'un épisode

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

- G_t est accessible à la fin de l'épisode \Leftrightarrow peut on éviter cette attente?

Méthodes "Temporal-difference" pour la fonction de valeurs

On veut estimer la valeur des états pour une politique fixe π .

$$\begin{aligned}v_{\pi}(s) &= \mathbb{E}_{\pi}[G_t \mid s_t = s] \\ &= \mathbb{E}_{\pi}[r_{t+1} + \gamma \sum_{k=0}^{\infty} \gamma^k r_{t+k+2} \mid s_t = s] \\ &= \mathbb{E}_{\pi}[r_{t+1} + \gamma v_{\pi}(s_{t+1}) \mid s_t = s]\end{aligned}$$

- Méthode Monte Carlo "chaque visite"

- estimation à l'aide du véritable gain G_t obtenu lors d'un épisode

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

- G_t est accessible à la fin de l'épisode \Leftrightarrow peut on éviter cette attente?

- Autre méthode TD(0)

$$v(s_t) \leftarrow v(s_t) + \alpha[r_{t+1} + \gamma v(s_{t+1}) - v(s_t)]$$

mise à jour à l'aide de $r_{t+1} + \gamma v(s_{t+1})$

Méthodes "Temporal-difference" pour la fonction de valeurs

$$v(s_t) \leftarrow v(s_t) + \alpha [r_{t+1} + \gamma v(s_{t+1}) - v(s_t)]$$

Méthode de différences temporelles : on calcule une erreur entre l'estimation $v(s_t)$ et l'estimation $r + \gamma v(s_{t+1})$.

et on voit apparaître une différence entre deux temps $t + 1$ et t .

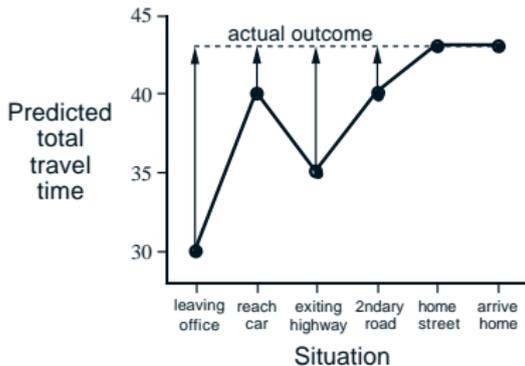
exemple du temps de trajet

Etat	temps écoulé	temps estimé	temps total prédit
départ du bureau	0	30	30
arrivée à la voiture, il pleut	5	35	40
sortie de l'autoroute	20	15	35
camion lent	30	10	40
arrivée dans le quartier	40	3	43
arrivée à la maison	43	0	43

exemple du temps de trajet

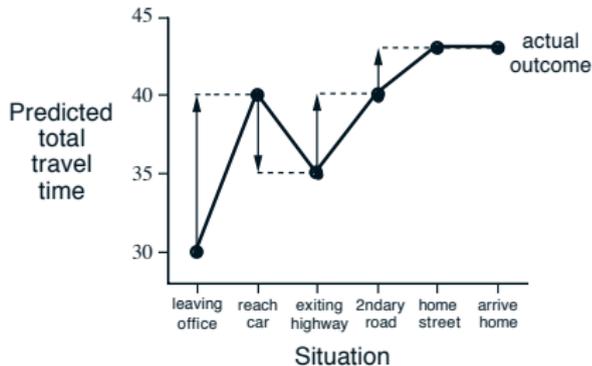
update avec méthode
de Monte Carlo

$\alpha = 1$



update avec TD(0)

$\alpha = 1$



Avantages des méthodes TD

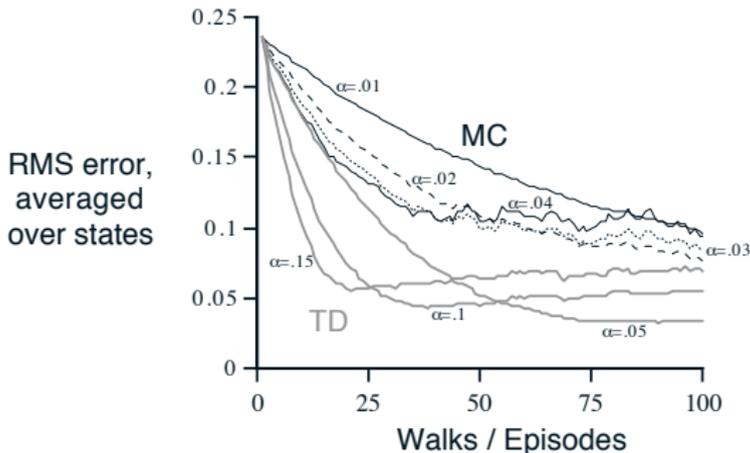
- pas besoin de connaissances des modèles
- méthode adaptée pour une utilisation online, et pas besoin d'attendre la fin de l'épisode
 - les méthodes TD font une mise à jour après chaque itération
- il y a des garanties théoriques de convergence

Avantages des méthodes TD

- Pas de résultats théoriques comparant les performances des méthodes TD aux méthodes Monte Carlo.
- en pratique, les méthodes TD sont plus rapides sur des problèmes stochastiques.



équiprobabilité d'aller à gauche ou à droite.



Exemple intuitif

On a un PDM a deux états A et B . Supposons qu'on observe les huit épisodes suivants :

$B,0$ $B,1$
 $B,1$ $B,1$
 $B,1$ $B,1$
 $B,1$ $A,0,B,0$

Quel est votre évaluation pour $v(A)$ et $v(B)$?

Evaluation de la politique optimale : TD "on policy"

- On apprend la fonction de valeur des actions.
- Comme pour TD(0) pour la fonction de valeurs, on a :

$$q(s_t, a_t) \leftarrow q(s_t, a_t) + \alpha [r_{t+1} + \gamma q(s_{t+1}, a_{t+1}) - q(s_t, a_t)]$$

State-action-reward-state-action (SARSA)

- 1 Initialise $q(s, a) \in \mathbb{R}$ arbitrairement (par exemple $q(s, a) = 0$)
- 2 Répète (éternellement) pour chaque épisode
- 3 aller à l'état initial s
- 4 choisir action $a \in A$ pour s à l'aide d'une politique dérivée de q (ex : ϵ -greedy)
- 5 Répète pour chaque étape de l'épisode
- 6 Exécute action a , observe $r \in \mathbb{R}$ et état suivant $s' \in S$
- 7 **si** s' est final
- 8 $q(s, a) \leftarrow q(s, a) + \alpha [r - q(s, a)]$
- 9 **sinon**
- 10 choisir action $a' \in A$ pour s' à l'aide d'une politique dérivée de q
- 11 $q(s, a) \leftarrow q(s, a) + \alpha [r + \gamma q(s', a') - q(s, a)]$
- 12 $s \leftarrow s'$
- 13 $a \leftarrow a'$
- 14 jusqu'à ce que s soit terminal

Théorème

SARSA converge vers la fonction optimale de valeur des actions sous les conditions suivantes :

- Glouton à la Limite avec Exploration Infinie (GLEI)
 - toutes les paires (état, action) sont explorées infiniment souvent $\lim_{k \rightarrow \infty} n_k(s, a) = \infty$
 - la politique converge vers une politique gloutonne $\lim_{k \rightarrow \infty} \pi_k(a|s) = 1$ pour $a = \arg \max_{a' \in A} q(s, a')$
- $\sum_{t=1}^{\infty} \alpha_t = \infty$
- $\sum_{t=1}^{\infty} \alpha_t^2 < \infty$

ϵ -greedy est GLEI si ϵ est une fonction décroissante (ex $e_k = \frac{1}{k}$)

Q-learning (Watkins 1989)

$$q(s_t, a_t) \leftarrow q(s_t, a_t) + \alpha \left[r_{t+1} + \gamma \max_{a \in A} q(s_{t+1}, a) - q(s_t, a_t) \right]$$

Apprend une estimation de q^* de façon indépendante à la politique suivie.

- 1 Initialise $q(s, a) \in \mathbb{R}$ arbitrairement (par exemple $q(s, a) = 0$)
- 2 Répète (éternellement) pour chaque épisode
- 3 aller à l'état initial s
- 4 choisir action $a \in A$ pour s à l'aide d'une politique dérivée de q (ex : ϵ -greedy)
- 5 Répète pour chaque étape de l'épisode
- 6 Exécute action a , observe $r \in \mathbb{R}$ et état suivant $s' \in S$
- 7 **si** s' est final
- 8 $q(s, a) \leftarrow q(s, a) + \alpha [r - q(s, a)]$
- 9 **sinon**
- 8 $q(s, a) \leftarrow q(s, a) + \alpha [r + \gamma \max_{a' \in A} q(s', a') - q(s, a)]$
- 7 choisir action $a' \in A$ pour s' à l'aide d'une politique dérivée de q
- 9 $s \leftarrow s'$
- 10 $a \leftarrow a'$
- 11 jusqu'à ce que s soit terminal

- Pour assurer la convergence, il faut s'assurer de visiter suffisamment souvent les paires (action, état).
- sous les hypothèses GLEI, Q-learning converge

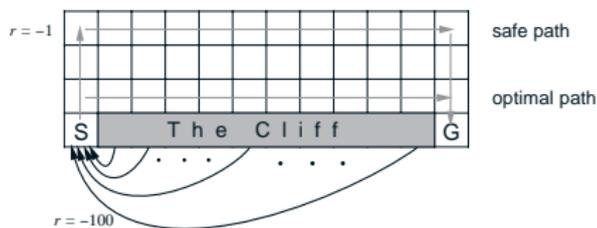
Théorème

Q-learning converge vers la fonction optimale de valeur des actions sous les conditions suivantes :

- Glouton à la Limite avec Exploration Infinie (GLEI)
 - toutes les paires (état, action) sont explorées infiniment souvent $\lim_{k \rightarrow \infty} n_k(s, a) = \infty$
 - la politique converge vers une politique gloutonne $\lim_{k \rightarrow \infty} \pi_k(a|s) = 1$ pour $a = \arg \max_{a' \in A} q(s, a')$
- $\sum_{t=1}^{\infty} \alpha_t = \infty$
- $\sum_{t=1}^{\infty} \alpha_t^2 < \infty$

Comparaison SARSA/Q-learning

Sous les hypothèses GLEI, les deux algorithmes convergent vers une solution optimale. Cependant, ils vont peut-être passer par des "étapes" différentes lors de l'apprentissage. Dans l'exemple, SARSA va souvent apprendre d'abord une politique sous-optimale avant de trouver la politique optimale. Q-learning va quant à lui trouver rapidement la politique optimale.



Autres méthodes d'exploration

- soft max : choisir l'action a avec probabilité

$$\frac{e^{\frac{q_t(s,a)}{\tau}}}{\sum_{a' \in A} e^{\frac{q_t(s,a')}{\tau}}}$$

- $\tau > 0$ est appelée la température
- température haute \Rightarrow probabilité uniforme
- température basse \Rightarrow approche le comportement glouton
- initialisation optimiste : initialiser les valeurs de manière optimiste puis être glouton (Even-Dar & Mansour, NIPS 1994)
 - \Rightarrow force l'exploration à regarder les états qui semblent prometteur

Dilemme central : explorer ou exploiter

- contrairement au cas supervisé, les données sur lesquelles on travaille dépendent du comportement de l'agent!
 - exploration : le but est d'apprendre le mieux possible
 - exploitation : le but est d'optimiser au mieux ses récompenses
 - défi de l'exploration : quelles actions vont améliorer au plus vite la connaissance de l'agent pour obtenir de meilleures récompenses.
- ➡ l'exploration est un trait d'intelligence
- quelle politique doit suivre l'agent pour ne pas manquer les états qui donnent les bonnes récompenses (et sans passer trop de temps dans les états qui donnent de mauvaises récompenses)
 - exploitation : préfère des actions qui ont mené à de "bons états"
 - exploration : prendre une action qui pourrait nous mener à de bons états.

Stratégie d'exploration

- ϵ -greedy
 - facile à implémenter et très utilisée
 - convergence garantie (avec un taux d'exploration qui décroît de bonne manière)
 - il faut un nombre exponentiel d'échantillons pour garantir convergence
- Boltzmann
 - même problème pour le nombre d'échantillons

Types d'algorithmes pour

- évaluer une politique donnée
- trouver une politique optimale

Algorithmes :

- modèle de transition et de récompenses connus \Rightarrow policy/value iteration
- Algorithmes pour domaines épisodique \Rightarrow méthodes de Monte Carlo
- Algorithme qui fonctionne sans connaître ni bâtir un modèle
Attention au dilemme Exploration Vs Exploitation
 \Rightarrow SARSA , Q-learning **mais** le nombre d'échantillons exponentiel est requis pour la convergence.
- d'autres algorithmes existent (double Q-learning, n-step SARSA, expected-SARSA, ...)
- Il existe des algorithmes qui fonctionnent en bâtissant un modèle
 $\Rightarrow E^3, R_{\max}$
mais qui nécessitent un nombre d'échantillons polynomial.

Ces méthodes sont des méthodes "tabulaires" : elles supposent que l'on peut stocker dans la table $Q(s,a)$ toutes les valeurs.