

# Apprentissage actif avec PDA

**ACTIVE**  
**function** ~~PASSIVE~~ **ADP-AGENT**(*percept*) **returns** an action  
**inputs:** *percept*, a percept indicating the current state  $s'$  and reward signal  $r'$   
**persistent:**  $\pi$ , a fixed policy  
 $mdp$ , an MDP with model  $P$ , rewards  $R$ , discount  $\gamma$   
 $U$ , a table of utilities, initially empty  
 $N_{sa}$ , a table of frequencies for state–action pairs, initially zero  
 $N_{s'|sa}$ , a table of outcome frequencies given state–action pairs, initially zero  
 $s, a$ , the previous state and action, initially null

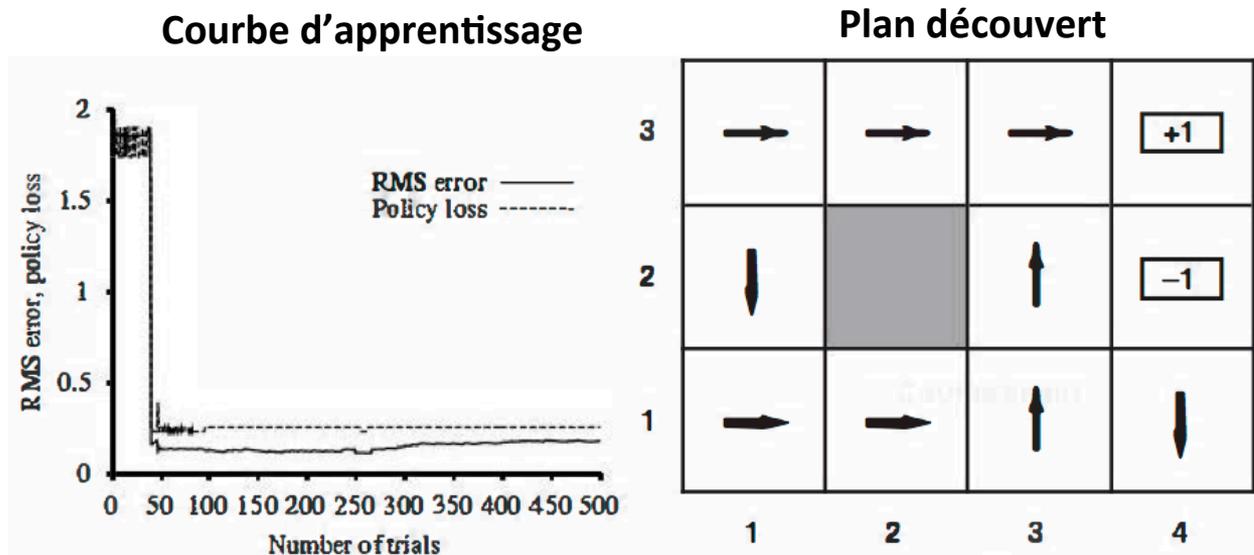
**if**  $s'$  is new **then**  $U[s'] \leftarrow r'$ ;  $R[s'] \leftarrow r'$       **Value iteration**  
**if**  $s$  is not null **then**  
    increment  $N_{sa}[s, a]$  and  $N_{s'|sa}[s', s, a]$        $V(s) = R(s) + \max_a \gamma \sum_{s' \in S} P(s'|s, a) V(s')$   
    **for each**  $t$  such that  $N_{s'|sa}[t, s, a]$  is nonzero **do**  
         $P(t|s, a) \leftarrow N_{s'|sa}[t, s, a] / N_{sa}[s, a]$   
     $U \leftarrow$  **POLICY-EVALUATION**( $\pi, U, mdp$ )  
**if**  $s'$ .**TERMINAL?** **then**  $s, a \leftarrow$  null **else**  $s, a \leftarrow$   ~~$s', \pi[s']$~~   $\leftarrow \operatorname{argmax}_{a \in A(s)} \sum_{s' \in S} P(s|s', a) V(s)$   
**return**  $a$

# Dilemme exploration vs. exploitation

- L'approche précédente est dite **vorace (gloutonne)**
  - ◆ elle met à jour le plan suivi par celui qui est optimal **maintenant**
  - ◆ en d'autres mots, **elle exploite le plus possible** l'information recueilli jusqu'à maintenant
- Les approches voraces trouvent rarement le plan optimal
  - ◆ elles ne tiennent pas compte du fait que l'**information accumulée jusqu'à maintenant est partielle**
  - ◆ en d'autres mots, elles ne considèrent pas la possibilité d'**explorer l'environnement** plus longuement, pour amasser plus d'information sur celui-ci
- Un parallèle similaire existe entre le *hill-climbing* et le *simulated annealing* en recherche locale

# Dilemme exploration vs. exploitation

- Exemple: cas où l'action « $\uparrow$ » n'a jamais été exécutée à l'état (1,2)
- L'agent ne sait pas que ça mène à (1,3), qui mène à un chemin plus court!



# Dilemme exploration vs. exploitation

- **Trop exploiter** mène à des plans non optimaux
- **Trop explorer** ralentit l'apprentissage inutilement
- Trouver la balance optimale entre l'exploration et l'exploitation est un problème ouvert en général
- Des stratégies d'exploration/exploitation optimales existent seulement dans des cas très simples
  - ◆ voir le cas du *n-armed bandit* dans le livre, p. 841

# Dilemme exploration vs. exploitation

- On se contente donc d'heuristiques en pratique
- Exemple: introduction d'une **fonction d'exploration**  $f(u,n)$ 
  - ◆ cette fonction augmente artificiellement les récompenses futures d'actions inexplorées
- L'approche par PDA basée sur *value iteration* ferait les mises à jour

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

où  $N(s,a)$  est le nombre de fois que l'action  $a$  a été choisie à l'état  $s$   
et

$$f(u,n) = \begin{cases} R^+ & \text{si } n < N_e \\ u & \text{sinon} \end{cases}$$

estimation optimiste de récompense future (hyper-paramètre)

- Garantit que  $a$  sera choisie dans  $s$  au moins  $N_e$  fois durant l'apprentissage