

MDP ONLINE

Labeled RTDP: Improving the Convergence of Real-Time Dynamic Programming
Bonet, B, Geffner, H. (2003)

Chafik EL MAHDAOUI
16 novembre 2017

Introduction

- Résoudre des MDPs
- Algorithme long : itération par valeur, itération par politique
- RTDP :
 - ne parcourt pas tout l'ensemble d'états
 - peut retourner une solution rapidement
- L-RTDP :
améliore la convergence de RTDP

Sommaire

1. Rappels
 - a) MDP
 - b) Itération par valeur
 - c) Exploration en ligne / hors ligne
2. RTDP
 - a) Principe
 - b) Exemple
 - c) Limite
3. L-RTDP
 - a) Principe
 - b) Exemple

Processus Décisionnel de Markov

- Systèmes stochastiques :
 - Une action = plusieurs états possibles
- Problème d'optimisation
- Formulation par
 - Coûts : minimiser le cout
 - Récompenses : maximiser la récompense
- Une décision : choix d'une action pour un état
- Un plan : ensemble de decision

Processus Décisionnel de Markov

Équation de Bellman (par coût)

$$V^*(s) = \min_{a \in A} \left(C(a) + \sum_{s' \in S} P(s', s, a) \times V(s') \right)$$

But : résoudre cette équation pour chaque états

Itération par valeur

- Itère sur tous les sommets
- Mets à jour la valeur des sommets grâce à l'équation de Bellman
- Jusqu'à ce que la fonction V converge

Exploration en ligne / hors ligne

- Hors ligne
 - Calculs tout les états avant de prendre une décision
 - Exemples : VI, PI ...
- En ligne
 - Prend une décision en fonction de l'état actuel et d'une fonction heuristique
 - Exemples : RTDP, L-RTDP

RTDP (Barto et al., 1995)


- Motivations :
 - MDP de grande taille
 - Obtenir un résultat « à tout moment »
- Algorithme glouton
- Réalise des essais
- Favorise les trajectoires les plus probables

RTDP - algorithmme


```
RTDP(s : state)
begin
  | repeat RTDPTRIAL(s)
end

RTDPTRIAL(s : state)
begin
  | while  $\neg s.GOAL()$  do
  |   | // pick best action and update hash
  |   | a = s.GREEDYACTION()
  |   |  $s.VALUE = c(s, a) + \sum_{s'} P_a(s'|s) \cdot s'.VALUE$ 
  |   | // stochastically simulate next state
  |   | s = s.PICKNEXTSTATE(a)
  | end
end
```


RTDP – exemple




RTDP – exemple




RTDP – exemple



RTDP – exemple



RTDP – exemple



Comparaison de RTDP et VI

- Résultats en fonction du temps
- Convergence vers un optimal
 - Quelques secondes pour VI
 - Plus de 10 minutes pour RTDP





Figure 2: Racetrack for `large-ring`. The initial and goal positions marked on the left and right



L-RTDP (Bonet and Geffner. 2003)

- RTDP + label « résolu » sur les états
- Évite les états déjà visités
- Visites plus d'états différents
- Fini lorsque l'état initial est « résolu »



Améliorer la convergence de RTDP

L-RTDP - algorithme

```
LRTDP(s : state,  $\epsilon$  : float)
begin
  while  $\neg$ s.SOLVED do LRTDPTRIAL(s,  $\epsilon$ )
end

LRTDPTRIAL(s : state,  $\epsilon$  : float)
begin
  visited = EMPTYSTACK
  while  $\neg$ s.SOLVED do
    // insert into visited
    visited.PUSH(s)

    // check termination at goal states
    if s.GOAL() then break

    // pick best action and update hash
    a = s.GREEDYACTION()
    s.UPDATE()

    // stochastically simulate next state
    s = s.PICKNEXTSTATE(a)


    // try labeling visited states in reverse order
    while visited  $\neq$  EMPTYSTACK do
      s = visited.POP()
      if  $\neg$ CHECKSOLVED(s,  $\epsilon$ ) then break
end
```

Algorithm 4: LRTDP.

L-RTDP – algorithme (suite)

CHECKSOLVED :

Vérifie que tous les états accessibles à partir de l'état s en appliquant la meilleure action a sont résolus ou ont convergé



Si oui, l'algorithme marque résolu l'état courant et les états accessibles par l'action a
Si non, il les mets à jour (applique l'équation de Bellman)

L-RTDP – algorithme (suite)

CHECKSOLVED($s : state, \epsilon : float$)

begin

$rv = true$

$open = EMPTYSTACK$

$closed = EMPTYSTACK$

if $\neg s.SOLVED$ **then** $open.PUSH(s)$

while $open \neq EMPTYSTACK$ **do**

$s = open.POP()$

$closed.PUSH(s)$

// check residual

if $s.RESIDUAL() > \epsilon$ **then**

$rv = false$

continue

// expand state

$a = s.GREEDYACTION()$

foreach s' such that $P_a(s', s) > 0$ **do**

if $\neg s'.SOLVED \ \& \ \neg IN(s', open \cup closed)$

$open.PUSH(s')$

[...]

Vérifie que tous les états accessibles à partir de l'état s en appliquant la meilleure action a sont résolus ou ont convergé

[...]

if $rv = true$ **then**

// label relevant states

foreach $s' \in closed$ **do**

$s'.SOLVED = true$

else

// update states with residuals and ancestors

while $closed \neq EMPTYSTACK$ **do**


$s = closed.POP()$

$s.UPDATE()$


return rv

end


L-RTDP – exemple




L-RTDP – exemple




L-RTDP – exemple




L-RTDP – exemple




L-RTDP – exemple




L-RTDP – exemple




L-RTDP – exemple




L-RTDP – exemple



L-RTDP – exemple



L-RTDP – exemple



Résultats de L-RTDP

- Coût moyen en fonction du temps





Figure 2: Racetrack for large-ring. The initial and goal positions marked on the left and right

Résultats de L-RTDP

- Convergence vers un optimal améliorée

algorithm	small-b	large-b	h-track	small-r	large-r	small-s	large-s	small-y	large-y
VI($h = 0$)	1.101	4.045	15.451	0.662	5.435	5.896	78.720	16.418	61.773
ILAO*($h = 0$)	2.568	11.794	43.591	1.114	11.166	12.212	250.739	57.488	182.649
LRTDP($h = 0$)	0.885	7.116	15.591	0.431	4.275	3.238	49.312	9.393	34.100

Table 2: Convergence time in seconds for the different algorithms with initial value function $h = 0$ and $\epsilon = 10^{-3}$. Times for RTDP not shown as they exceed the cutoff time for convergence (10 minutes). Faster times are shown in bold font.

algorithm	small-b	large-b	h-track	small-r	large-r	small-s	large-s	small-y	large-y
VI(h_{min})	1.317	4.093	12.693	0.737	5.932	6.855	102.946	17.636	66.253
ILAO*(h_{min})	1.161	2.910	11.401	0.309	3.514	0.387	1.055	0.692	1.367
LRTDP(h_{min})	0.521	2.660	7.944	0.187	1.599	0.259	0.653	0.336	0.749

Table 3: Convergence time in seconds for the different algorithms with initial value function $h = h_{min}$ and $\epsilon = 10^{-3}$. Times for RTDP not shown as they exceed the cutoff time for convergence (10 minutes). Faster times are shown in bold font.

Conclusion

- Ajouter la notion de « label » à RTDP
 - Améliore la convergence
 - Trouve un résultat rapidement
 - converge en temps fini
- Processus de labélisation est complexe

MERCI DE VOTRE ATTENTION