

Sistemi Intelligenti Reinforcement Learning: Temporal Difference

Alberto Borghese

Università degli Studi di Milano
Laboratorio di Sistemi Intelligenti Applicati (AIS-Lab)
Dipartimento di Scienze dell'Informazione

borghese@dsi.unimi.it



A.A. 2012-2013

1/28

<http://homes.dsi.unimi.it/~borghese/>



Sommario



Temporal differences

SARSA

A.A. 2012-2013

2/28

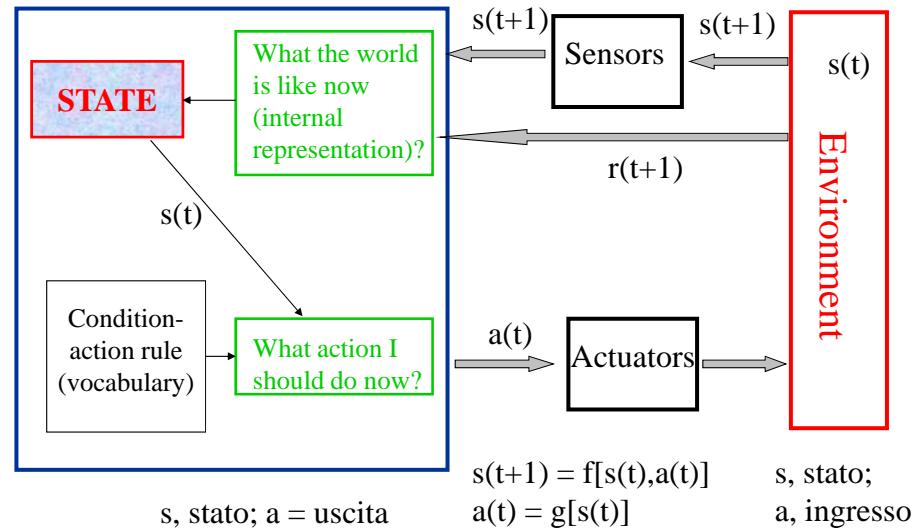
<http://homes.dsi.unimi.it/~borghese/>



Schematic diagram of an agent



Agent



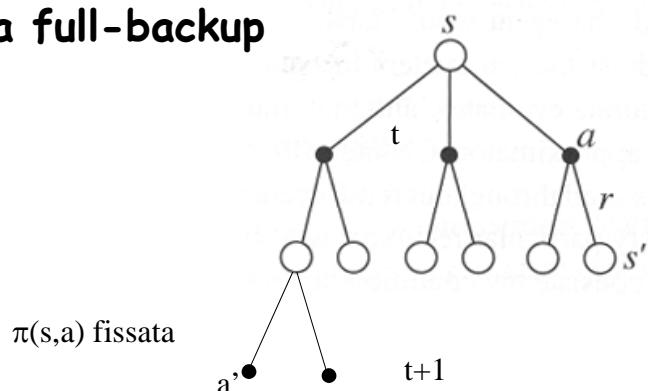
A.A. 2012-2013

3/28

<http://homes.dsi.unimi.it/~borgheze/>

Tecnica full-backup

Back-up



Conosciamo $Q_k(s_t, a_t) \forall s_t$, anche per s'_{t+1} quindi:

Analizziamo la transizione da $s_t, a_t \rightarrow (s'_{t+1}, a'_{t+1})$

Calcoliamo un nuovo valore di Q per s, a : $Q_{k+1}(s_t, a_t)$ congruente con:

$Q_k(s_{t+1}, a_{t+1})$ ed r_{t+1}

Full backup se esaminiamo tutti gli s', a' (cf. DP).

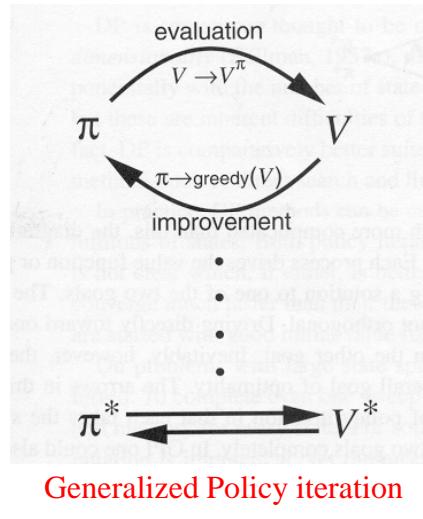
Da s' mi guardo indietro ed aggiorno $Q(s, a)$.

π fissata

A.A. 2012-2013

4/31

<http://homes.dsi.unimi.it/~borgheze/>



Schema di Apprendimento

Competizione e cooperazione -> V corretta e policy ottimale.

A.A. 2012-2013

5/28

<http://homes.dsi.unimi.it/~borgesel>



World RL competition



Started in NIP2006.

It became very popular and started a workshop on its own. Visit:

<http://rl-competition.org>

A.A. 2012-2013

6/28

<http://homes.dsi.unimi.it/~borgesel>



How About Learning the Value Function?



Facciamo imparare all'agente la value function, per una certa politica: V^π :

$$Q^\pi(s, a) = \sum_{s'} P_{s \rightarrow s'|a} \left[R_{s \rightarrow s'|a} + \gamma \sum_{a'} \pi(a', s) Q^\pi(s', a') \right]$$

È una funzione dello stato.

Una volta imparata la value function, Q^* , l'agente seleziona la policy ottima passo per passo, "one step lookahead":

$$\pi^*(s) = \arg \max_{a'} \sum_{s'} P_{s \rightarrow s'|a}^a [R_{s \rightarrow s'|a} + \gamma V^\pi(s')]$$

Full backup, for all states



Value iteration



Facciamo imparare all'agente la value function, per una certa politica: Q^π , analizzando quello che succede in uno step temporale:

$$Q_{k+1}(s, a) = \sum_{s'} P_{s \rightarrow s'|a} \left[R_{s \rightarrow s'|a} + \gamma \left(\sum_{a'_j} \pi(a'_j, s) Q_k(s', a') \right) \right]$$

Invece di considerare una policy stocastica, consideriamo l'azione migliore:

L'apprendimento della policy si può inglobare nella value iteration:

$$Q_{k+1}(s, a) = \max_{a'} \sum_{s'} P_{s \rightarrow s'|a} [R_{s \rightarrow s'|a} + \gamma Q_k(s', a')] \quad \forall s, a$$



Problema legato alla conoscenza della risposta dell'ambiente



$$Q_{k+1}(s, a) \leftarrow \max_a \sum_{s'} P_{s \rightarrow s'|a} \left[R_{s \rightarrow s'|a} + \gamma \sum_{a'} \pi(s', a') Q_k(s', a') \right]$$

Full backup, single state, s, all future states s'

Fino a questo punto, è noto un modello dell'ambiente:

- R(.)
- P(.)

Environment modeling -> Value function computation -> Policy optimization.



Osservazioni



Iterazione tra:

- Calcolo della Value function

$$Q_{k+1}(s, a) = \sum_{s'} P_{s \rightarrow s'|a} \left[R_{s \rightarrow s'|a} + \gamma \left[\sum_{a'} \pi(a', s') Q_k(s', a') \right] \right]$$

- Miglioramento della policy

$$= \arg \max_{a'} \sum_{s'} P_{s \rightarrow s'|a} \left[R_{s \rightarrow s'|a} + \gamma Q^{\pi}(s', a') \right]$$

Non sono noti



Background su Temporal Difference (TD) Learning



Al tempo t abbiamo a disposizione:

$$r_{t+1} = r' \quad R_{s \rightarrow s'|a_j}$$

$$s_{t+1} = s' \quad P_{s \rightarrow s'|a_j}$$

Reward certo
Transizione certa
vengono misurati dall'ambiente

Come si possono utilizzare per apprendere?



Confronto con il setting associativo



$$Q_{k+1} = Q_k - \frac{Q_k}{N_{k+1}} + \frac{r_{k+1}}{N_{k+1}} = \boxed{Q_k + \alpha[r_{k+1} - Q_k]}$$

Occupazione di memoria minima: Solo Q_k e k .
NB k è il numero di volte in cui è stata scelta a_j .

Questa forma è la base del RL. La sua forma generale è:

$$\begin{aligned} NewEstimate &= OldEstimate + StepSize [Target - OldEstimate] \\ NewEstimate &= OldEstimate + StepSize * Error. \end{aligned}$$

$$StepSize = \alpha = 1/k$$

$$Rewards\ weight w = 1$$

$$a = cost$$

$$Weight\ of\ i-th\ reward\ at\ time\ k: w = (1-a)^{k-i}$$

Qual è la differenza introdotta dall'approccio DP?



Un possibile aggiornamento



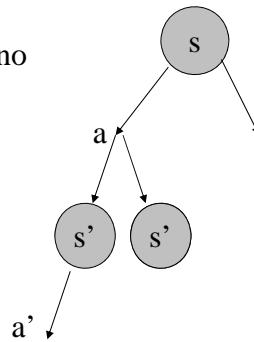
In iterative policy evaluation ottengo questo aggiornamento:

$$Q_{k+1}(s, a) = \sum_{s'} P_{s \rightarrow s'|a} \left[R_{s \rightarrow s'|a} + \gamma \left[\sum_{a'} \pi(a', s') Q_k(s', a') \right] \right]$$

Ad ogni istante di tempo di ogni trial aggiorno la Value function:

$$Q_{k+1}(s, a) = [r' + \gamma Q_k(s', a')]$$

Qual'è il problema?



A.A. 2012-2013

13/28

<http://homes.dsi.unimi.it/~borgheze/>



Un possibile aggiornamento di $Q(s, a)$



$$Q_{k+1} = Q_k - \frac{Q_k}{N_{k+1}} + \frac{r_{k+1}}{N_{k+1}} = Q_k + \alpha[r_{k+1} - Q_k] = Q_k + \Delta Q_k$$

Quanto vale α ?

$$Q_k(s, a) = Q_k(s, a) + \Delta Q_k(s, a)$$

Come calcolo $\Delta Q_k(s, a)$?

A.A. 2012-2013

14/28

<http://homes.dsi.unimi.it/~borgheze/>



TD(0) update



Ad ogni istante di tempo di ogni trial aggiorno la Value function:

$$Q_{k+1}(s_t, a_t) = Q_k(s_t, a_t) + \alpha [r_{t+1} + \gamma Q_k(s_{t+1}, a_{t+1}) - Q_k(s_t, a_t)]$$

Da confrontare con la iterative policy evaluation:

$$Q_{k+1}(s, a) = \sum_{s'} P_{s \rightarrow s'|a} \left[R_{s \rightarrow s'|a} + \gamma \left[\sum_{a'} \pi(a', s') Q_k(s', a') \right] \right]$$

**Sample
backup**

E con il valore di uno stato sotto la policy $\pi(s, a)$:

$$Q^\pi(s, a) = E_\pi \{R_t | s_t = s, a_t = a\} = E_\pi \{r_{t+1} + \gamma Q^\pi(s', a') | s_t = s, a_t = a\}$$

Quanto vale α ?



Confronto con il setting associativo



$$Q_{k+1} = Q_k - \frac{Q_k}{N_{k+1}} + \frac{r_{k+1}}{N_{k+1}} = \boxed{Q_k + \alpha [r_{k+1} - Q_k]}$$

Occupazione di memoria minima: Solo Q_k e k .

NB k è il numero di volte in cui è stata scelta a_j .

Questa forma è la base del RL. La sua forma generale è:

$$\begin{aligned} NewEstimate &= OldEstimate + StepSize [Target - OldEstimate] \\ NewEstimate &= OldEstimate + StepSize * Error. \end{aligned}$$

$$StepSize = \alpha = 1/k \quad a = cost$$



Setting α value



$\alpha(s_t, a_t, s_{t+1}) = 1/k(s_t, a_t, s_{t+1})$, where k represents the number of occurrences of s_t, a_t, s_{t+1} . With this setting the estimated Q tends to the expected value of $Q(s,a)$.

Per semplicità si assume solitamente $\alpha < 1$ costante. In questo caso, $Q(s,a)$ assume il valore di una media pesata dei reward a lungo termine collezionati da (s,a) , con peso: $(1-\alpha)^k$: *exponential recency-weighted average*.



Sommario

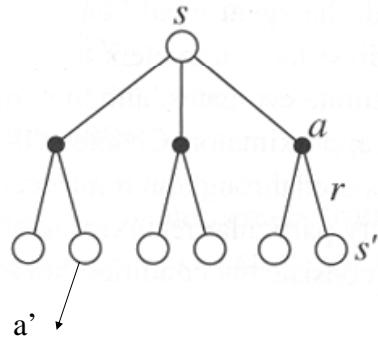


Temporal differences

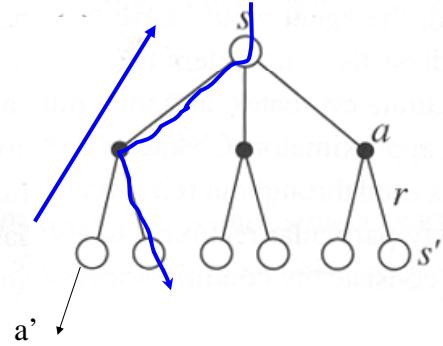
SARSA



Sample backup



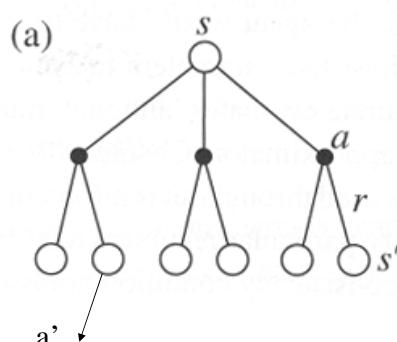
Full backup



Single sample is evaluated



Sample backup



SARSA algorithm

State –
Action –
Reward –
State (next) –
Action (next)



Algoritmo per TD(0) - Progetto per esame (da completare con scelta della policy)



Inizializziamo $Q(s,a) = 0$.

Inizializziamo la policy: $\pi(s,a)$.da valutare

Repeat

{ $s = s_0; a = \pi(s);$

 Repeat // For each state until terminal state, analyze an episode

 { $s_{\text{next}} = \text{NextState}(s, a);$

 reward = Reward(s, s_{next}, a);

$a_{\text{next}} = \pi(s_{\text{next}})$

$Q(s,a) = Q(s,a) + \alpha [\text{reward} + \gamma Q(s_{\text{next}}, a_{\text{next}}) - Q(s,a)];$

$s = s_{\text{next}}; a = a_{\text{next}};$

 } until TerminalState

} Until convergence of $Q(s,a)$ for policy $\pi(s,a)$

A.A. 2012-2013

21/28

<http://homes.dsi.unimi.it/~borgheze/>



Esempio: valutazione della policy TD



Stato	Tempo trascorso attuale	Tempo percorrenza attuale del segmento	Tempo percorrenza stimato fino ad ora del segmento	Tempo totale previsto precedenza - $Q_k(s',a')$	Tempo totale previsto aggiornato - $Q_{k+1}(s,a)$	Increase or decrease - $Q(s,a)$
Esco dall'ufficio	0	0	0	43	$43 + \alpha(5 + 38 - 43)$ =	=
Salgo in auto	5	5	5	38	$38 + \alpha(10 + 23 - 38)$ <	<
Esco dall'autostrada	15	10	15	23	$23 + \alpha(7 + 18 - 23)$ >	>
Strada secondaria con camion davanti	22	7	5	18	$18 + \alpha(10 + 13 - 18)$ >	>
Strada di casa	32	10	5	13	$13 + \alpha(10 + 3 - 13)$ =	=
Entro in casa	42	10	10	3	$3 + \alpha(5 + 3 - 3)$ >	>
	47	5	3	0	0	

$Q(s,a)$ è l'expected "Time-to-Go" - $\gamma = 1$

A.A. 2012-2013

22/28

<http://homes.dsi.unimi.it/~borgheze/>



Ruolo di α



$$Q(1, a_1) = (1, a_1) + \alpha (r_1 + \gamma (2, a_2) - Q(1)) = 38 + \alpha (10 + 23 - 38) = 38 - \alpha * 5$$

Stima iniziale del tempo di percorrenza dal parcheggio: 38m

Tempo di percorrenza fino ad uscita autostrada: 10m

Stima del tempo di percorrenza dall'uscita autostrada: 23m

$$\alpha < 1.$$

If $\alpha \ll 1$ aggiorno molto lentamente la value function.

If $\alpha = 1/k$ aggiorno la value function in modo da tendere al valore atteso. Devo memorizzare le occorrenze dello stato s.

If $\alpha = \text{cost}$. Aggiorno la value function, pesando maggiormente i risultati collezionati dalle visite dello stato più recenti.



Proprietà del metodo TD



Non richiede conoscenze a priori dell'ambiente.

L'agente stima dalle sue stime precedenti (bootstrap).

Si dimostra che il metodo converge asintoticamente.

Batch vs trial learning.

Converge!!

$$Q^\pi(s_t, a_t) = Q^\pi(s_t, a_t) + \alpha [r_{t+1} + \gamma Q^\pi(s_{t+1}, a_{t+1}) - Q^\pi(s_t, a_t)]$$

Single backup, single state, s_t , single future state s_{t+1}

Rimpiazza iterative Policy evaluation.

Rimane il passo di Policy iteration (improvement).



SARSA Algorithm (progetto)



```

Q(s,a) = rand(); // ∀s, ∀a, eventualmente Q(s,a) = 0
Repeat // for each episode
{
    s = s0;
    Repeat // for each step of the single episode
    {
        a = Policy(s); // ε-greedy??
        s_next = NextState(s,a);
        reward = Reward(s,s_next,a);
        a_next = Policy(s_next); // ε-greedy?
        Q(s,a) = Q(s,a) + α [reward + γ Q(s_next, a_next) - Q(s,a)];
        s = s_next;
    } // until last state
} // until the end of learning

```

- 1) Apprendiamo il valore di Q per una policy data (on-policy).
- 2) Dopo avere appreso la funzione Q, possiamo modificare la policy in modo da migliorarla.

Come integrare i due passi?

A.A. 2012-2013

25/28

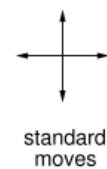
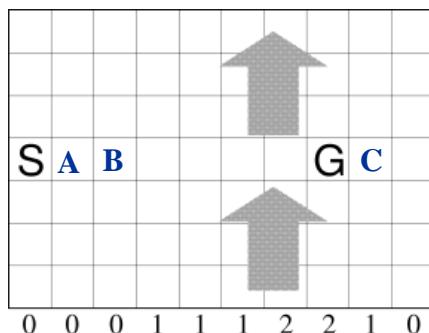
<http://homes.dsi.unimi.it/~borgheste/>



Esempio



From Start to Goal.



Upwards wind

$Q(s,a)$ iniziale = 0.

$r = 0$ se $s' = G$; altrimenti $r = -1$.

$\pi(s,a)$ data.

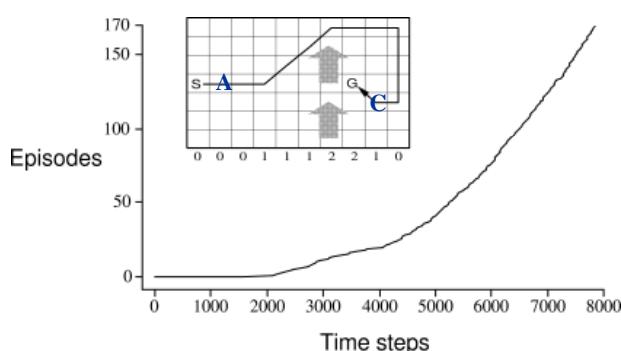
A.A. 2012-2013

26/28

<http://homes.dsi.unimi.it/~borgheste/>



Esempio - risultato



Policy π , greedy

or ϵ -greedy

$$\epsilon = 0.1$$

$$\alpha = 0.5$$

$$\gamma = 1$$

Per trial or
per epoch

Al termine,
policy
improvement.

Correzione di Q ad un passo:

$$Q(S, \text{east}) = 0 + 0.5 [-1 + 0 - 0] = -0.5$$

$$Q(A, \text{east}) = 0 + 0.5 [-1 + 0 - 0] = -0.5$$

$$Q(C, \text{west}) = 0 + 0.5 [0 + 0 - 0] = 0; \quad (\text{NB c'è il vento verso l'alto di 1})$$

A.A. 2010-2011
$$Q(s_t, a_t) = Q(s_t, a_t) + \alpha [r_{t+1} + \gamma Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t)]$$



Sommario



Temporal differences

SARSA