

Sistemi Intelligenti Reinforcement Learning: Q-learning

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. 2010-2011

1/31

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



Sommario



SARSA

Q-learning

A.A. 2010-2011

2/31


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



Le value function



$$V^\pi(s) = E_\pi\{R_t \mid s_t = s\} = E_\pi\left\{\sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \mid s_t = s\right\} = \left[\sum_{a_j} \pi(a_j, s) \right] \sum_{s'} P_{s \rightarrow s'|a_j} [R_{s \rightarrow s'|a_j} + \gamma V^\pi(s')]$$



$$Q^\pi(s, a) = E_\pi\{R_t \mid s_t = s, a_t = a\} = E_\pi\left\{\sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \mid s_t = s, a_t = a\right\}$$

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

A.A. 2010-2011

3/31

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



Serve davvero la Value Function?



La Value Function deriva dalla visione della Programmazione Dinamica.


Ma è proprio necessario conoscere la Value function (che riguarda gli stati)? In fondo a noi interessa determinare la Policy.

A.A. 2010-2011

4/31

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

 **Calcolo ricorsivo della value function Q** 



$$Q^\pi(s, a) = E_\pi\{R_t \mid s_t = s, a_t = a\} = E_\pi\left\{\sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \middle| s_t = s, a_t = a\right\}$$

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

A.A. 2010-2011 5/31 <http://homes.dsi.unimi.it/~borghese/>

 **Q Functions** 

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

$$V = \text{Cumulative reward of being in } s \text{ and choosing } a_j. Q^\pi(s, a_j) = \sum_{s'} P_{s \rightarrow s'|a_j} [R_{s \rightarrow s'|a_j} + \gamma V^\pi(s')]$$

Idea chiave:

- Unire il rinforzo che si ottiene passando da uno stato al successivo in un'unica funzione

$$Q(s, a) = [R_{s \rightarrow s'} + \gamma V^\pi(s')]$$

- Questa funzione valuta la bontà dell'azione e non più dello stato ($a = \pi(s)$).
- A questo punto posso massimizzare Q senza conoscere separatamente il reward istantaneo e la value function come:

$$\pi^*(s) = \operatorname{argmax}_a Q(s, a)$$

Q = Cumulative reward of being in s and taking action a .

A.A. 2010-2011 6/31 <http://homes.dsi.unimi.it/~borghese/>



Equazioni di ottimalità di Bellman



$V^*(s)$ di uno stato, quando viene scelta la policy ottima, deve essere uguale al valore atteso del reward per l'azione migliore per lo stato s .

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

$$Q^*(s, a_j) = \sum_{s'} P_{s \rightarrow s'|a_j} [R_{s \rightarrow s'|a_j} + \gamma \max_{a'} Q^*(s', a')]$$


A.A. 2010-2011

7/31

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



Relazione tra $Q_t(\cdot)$ e $Q_{t+1}(\cdot)$: rappresentazione grafica



$V(s_t)$

$V(s_{t+1})$

One step for Iterative policy Evaluation

$Q(s_t, a_t)$

$Q(s_{t+1}, a_{t+1})$

One step for Q-based policy Evaluation

A.A. 2010-2011

8/31

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



Come apprendere Q: SARSA




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

- 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 (**policy improvement**)

s = state, a = action, r = reward, s' = state, a' = action
è di tipo TD(0)



A.A. 2010-2011

9/31

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



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. 2010-2011



10/31

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

Esempio



From Start to Goal.



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

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

$\pi(s,a)$ data.

Upwards wind

A.A. 2010-2011

11/31

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

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:

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

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

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

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



Sommario



SARSA

Q-learning

A.A. 2010-2011

13/31

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



Come apprendere Q: SARSA




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

- 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 (**policy improvement**)

S = state, a = action, r = reward, s = state, a = action

On-policy learning.



A.A. 2010-2011

14/31

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



Value iteration



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

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

$$V_{k+1}(s) = \max_a \sum_{s'} P_{s \rightarrow s'|a} [R_{s \rightarrow s'|a} + \gamma V_k(s')]$$

VS

A.A. 2010-2011

15/31

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




Off-policy Temporal Difference: Q-learning



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

Non imparo semplicemente la funzione valore Q, ma la funzione valore Q ottima.

In s, scelgo un ramo del grafo, e poi **decido** ad un passo come continuare.



A.A. 2010-2011

16/31

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



Q-learning algorithm (progetto)



```

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

```

Max with respect to a_{next}


A.A. 2010-2011

17/31

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



Rappresentazione grafica



$Q(s_t, a_t)$ $Q(s_{t+1}, a_{t+1})$
 One step for **Q Iteration**

Viene migliorata la policy al tempo t+1.

A.A. 2010-2011

18/31


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



Example 1 - Q Learning Update



$$\gamma = 0.9$$



0 reward received in the transition

Esempio tratto dai lucidi del corso di Brian C. Williams su RL.

Modificati dalle slide di: Manuela Veloso, Reid Simmons, & Tom Mitchell, CMU

Apprendimento della funzione valore Q. Versione Q-learning. $Q(A,dx) = ?$

A	B	C
D	E	F

In grigio i valori di $Q(s,a)$.
Nessun reward istantaneo.

A.A. 2010-2011

19/31

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




Example 1 - Q Learning Update



$$\gamma = 0.9$$

$$\alpha = 0.1$$

$$a(s_2) = \text{down}$$



0 reward received in the transition



$$\begin{aligned} Q(s_1, a_{right}) &\leftarrow Q(s_1, a_{right}) + \alpha [r(s_1, a_{right}, s_2) + \gamma \max_a Q(s_2, a) - Q(s_1, a_{right})] \\ &\leftarrow 72 + \alpha [0 + 0.9 \max \{ 63, 80, 100 \} - Q(s_1, a_{right})] \\ &\leftarrow 72 + \alpha (90 - 72) = 72 + 1.8 = 73.8 \end{aligned}$$

Correzione di $Q(s_1, a_{right})$

Correzione dell'azione in s_2 da down a right

La correzione va a 0 quando $Q(s_1, a_{right}) = 90$

A.A. 2010-2011

20/31

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




Example 2: Q-Learning Iterations: Episodic



- Start at upper left; Initial selected policy: move clockwise; Table initially 0; $\gamma = 0.8$.

Possibili transizioni sono segnate con frecce nere e grigie.

Reward
istanteo in
rosso e
cerchiato



$$Q(s_t, a_t) \leftarrow r_{t+1} + \gamma \max_{a_{t+1}} Q(s_{t+1}, a_{t+1})$$

E.g. videogioco.

$Q(S1,E)$	$Q(s2,E)$	$Q(s3,S)$	$Q(s4,W)$
0			

A.A. 2010-2011

21/31

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




Q-Learning Iterations



- Start at upper left – move clockwise; table initially 0; $\gamma = 0.8$

$$Q(s, a) \leftarrow r + \gamma \max_{a'} Q(s', a')$$



$Q(S1,E)$	$Q(s2,E)$	$Q(s3,S)$	$Q(s4,W)$
0	0	0	

A.A. 2010-2011

22/31

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




Q-Learning Iterations



- Start at upper left – move clockwise; $\gamma = 0.8$

$$Q(s, a) \leftarrow r + \gamma \max_{a'} Q(s', a')$$



Q(S1,E)	Q(s2,E)	Q(s3,S)	Q(s4,W)
0	0	0	$r + \gamma \max_{a'} \{Q(s5a)\} = 10 + 0.8 \times 0 = \mathbf{10}$

A.A. 2010-2011

23/31

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




Q-Learning Iterations



- Start at upper left – move clockwise; $\gamma = 0.8$

$$Q(s, a) \leftarrow r + \gamma \max_{a'} Q(s', a')$$



Q(S1,E)	Q(s2,E)	Q(s3,S)	Q(s4,W)
0	0	0	$r + \gamma \max_{a'} \{Q(s5,a)\} = 10 + 0.8 \times 0 = 10$
0	0	$r + \gamma \max_{a'} \{Q(s4,W), Q(s4,N)\} = 0 + 0.8 \times \max\{10, 0\} = 8$	

A.A. 2010-2011

24/31

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




Q-Learning Iterations



- Start at upper left – move clockwise; $\gamma = 0.8$

$$Q(s, a) \leftarrow r + \gamma \max_{a'} Q(s', a')$$



Q(s1,E)	Q(s2,E)	Q(s3,S)	Q(s4,W)
0	0	0	$r + \gamma \max_{a'} \{Q(s5, \text{loop})\} = 10 + 0.8 \times 0 = 10$
0	0	$r + \gamma \max_{a'} \{Q(s4,W), Q(s4,N)\} = 0 + 0.8 \times \max\{10, 0\} = 8$	10
0	$r + \gamma \max_{a'} \{Q(s3,W), Q(s3,S)\} = 0 + 0.8 \times \max\{0, 8\} = 6.4$		

A.A. 2010-2011

25/31

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




Q-Learning Iterations: improving policy



- Start at upper left – move clockwise; $\gamma = 0.8$

$$Q(s, a) \leftarrow r + \gamma \max_{a'} Q(s', a')$$



$$\text{Calcolo } Q(s_2, S) = r + \gamma \max_{a'} \{Q(s5, \text{loop})\} = 10 + 0.8 \times 0 = \mathbf{10}$$

$$\begin{aligned} \text{Ricalcolo } Q(s_1, E) &= r + \gamma \max_{a'} \{Q(s2,E), Q(s2,W), Q(s2,S)\} = \\ &r + \gamma \max_{a'} \{6.4, 0.0, 10.0\} \rightarrow \mathbf{South = \pi(s_2)!} \end{aligned}$$

A.A. 2010-2011

26/31

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




Q-Learning Iterations



- Start at upper left – move clockwise; $\gamma = 0.8$

$$Q(s, a) \leftarrow r + \gamma \max_{a'} Q(s', a')$$


NB in B the new policy drives the agent towards the E state (loop).




$Q(s1, E)$	$Q(s2, E)$	$Q(s3, S)$	$Q(s4, W)$
0	0	0	$r + \gamma \max_{a'} \{Q(s5, \text{loop})\} = 10 + 0.8 \times 0 = 10$
0	0	$r + \gamma \max_{a'} \{Q(s4, W), Q(s4, N)\} = 0 + 0.8 \times \max\{10, 0\} = 8$	10
0	$r + \gamma \max_{a'} \{Q(s3, W), Q(s3, S)\} = 0 + 0.8 \times \max\{10, 8\} = 8.4$	8	10
8	6.4	8	10




Example 3 - Comparison of functions V and Q ($\gamma = 0.9$)



$R(s, a)$ values



$Q(s, a)$ values



$V^*(s)$ values

$$V^*(s) = \max(Q^*(s, a))$$

One Optimal Policy



Proprietà del rinforzo



L'ambiente o l'interazione può essere complessa.

Il rinforzo può avvenire solo dopo una più o meno lunga sequenza di azioni (**delayed reward**).

E.g. agente = giocatore di scacchi.
 ambiente = avversario.

Problemi collegati:

temporal credit assignement.
structural credit assignement.

L'apprendimento non è più da esempi, ma dall'osservazione del proprio comportamento nell'ambiente.



Esempio SW



- Labirinto

- Gatto & Topo



Sommario



SARSA

Q-learning