

# Sistemi Intelligenti Reinforcement Learning: SARSA and Q-learning

Alberto Borghese

Università degli Studi di Milano  
Laboratorio di Sistemi Intelligenti Applicati (AIS-Lab)

Dipartimento di Informatica

[alberto.borghese@unimi.it](mailto:alberto.borghese@unimi.it)

Barto and Sutton, 4.7, 6.4, 6.5



A.A. 2020-2021

1/49

<http://borgheze.di.unimi.it/>



## Sommario



**SARSA**

Q-learning

Esempi

A.A. 2020-2021

2/49

<http://borgheze.di.unimi.it/>



# Meccanismo di apprendimento nel RL



**Inizializzazione:** se l'agente non agisce sull'ambiente non succede nulla. Occorre specificare una policy iniziale.

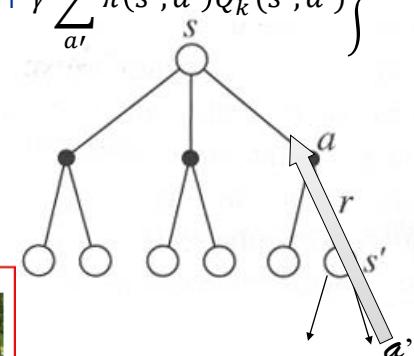
**Ciclo dell'agente (le tre fasi sono sequenziali):**

- 1) Implemento una policy ( $\pi(s,a)$ )
- 2) Calcolo la Value function ( $Q^\pi(s,a)$ )
- 3) Aggiorno la policy.

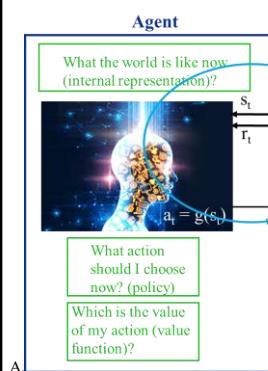


## Un ciclo di interazione

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



**Calcolo ricorsivo di Q(.)**



**Passo da t a t+1 poi  
guardo backwards in time**



# Meccanismo di apprendimento nel RL



**Inizializzazione:** se l'agente non agisce sull'ambiente non succede nulla. Occorre specificare una policy iniziale.

**Ciclo dell'agente (le tre fasi sono sequenziali):**

- 1) Implemento una policy ( $\pi(s,a)$ )
- 2) Determino la Value function ( $Q^\pi(s,a)$ )
- 3) Aggiorno la policy.



## Q(s,a) - Osservazioni

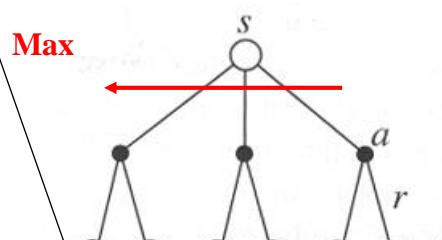


$$Q^\pi(s_t, a_t) = \sum_{s'} P_{s \rightarrow s' | a} \left\{ R_{s,s',a} + \gamma \sum_{a'} \pi(s', a') Q^\pi(s', a') \right\}$$

nota

Per ogni stato devo valutare con informazioni esclusivamente racchiuse in 1 passo l'azione migliore a lungo termine

$$a_{t_{new}} : \max_{a_t} Q^\pi(s_t, a_t)$$



E' supposto noto il funzionamento dell'ambiente (simulazione)



## Effetto del cambiamento della policy



Cambia,  $a$ , cambiano i possibili stati successivi ad  $s_t$ ,  $\{s_{t+k}\}$ , ed il reward a lungo termine:

$$Q^\pi(s_t, a_{new}) = E \left\{ r_{t+1} + \gamma \sum_{s'} Pr_{s_t \rightarrow s' | a_{new}} Q_k^\pi(s', a') | s_t = s, a_t = a \right\}$$

$$a_{new} = \pi(s_t) \neq a_t$$

$$Q^{\pi_{new}}(s_t, a_{new}) \stackrel{?}{=} Q^\pi(s_t, a_t)$$

Se il reward fosse migliore con  $a_{new}$ , sceglierò sempre  $a_{new}$  in  $s_t$ .

Il reward a lungo termine può essere maggiore (minore) solamente se aumenta (diminuisce) il reward totale “visto” ad un passo (reward del passo + reward successivo).



## Teorema del miglioramento della policy

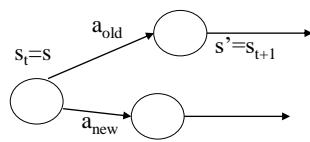


$$Q^\pi(s_t, a_{new}) = E \left\{ r_{t+1} + \gamma \sum_{s'} Pr_{s_t \rightarrow s' | a_{new}} Q_k^\pi(s', a') | s_t = s, a_t = a \right\}$$

**Ipotesi:**  $\pi$  and  $\pi'$  deterministic policies such that  $\forall s_t$

$$Q^{\pi'}(s_t, a_{new}) = \pi'(s_t) \geq Q^\pi(s_t, a_t) \quad \forall a_t$$

**Tesi:**  $\pi'$  è meglio di  $\pi$ . Cioè:  $Q^{\pi'}(s, \pi'(s)) \geq Q^\pi(s, \pi(s)) \quad \forall s$ .





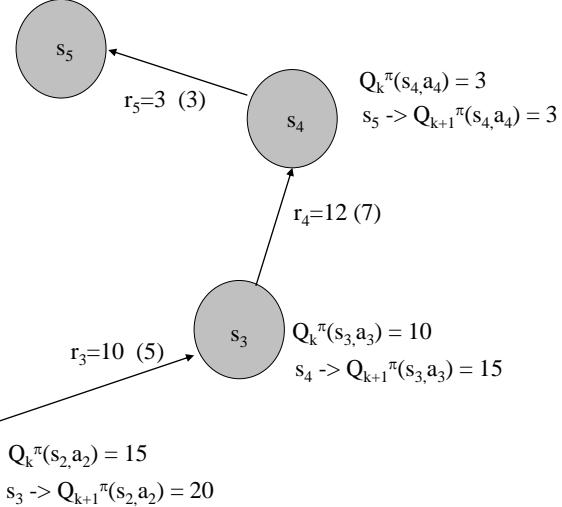
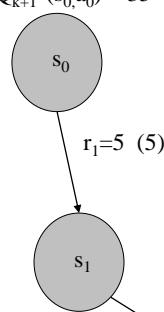
## Learning $Q^\pi(s, a)$



$s_0$  = ufficio;  $s_5$  = casa.

$$Q_k^\pi(s_0, a_0) = 35$$

$$s_1 \rightarrow Q_{k+1}^\pi(s_0, a_0) = 35$$



Come i diversi reward istantanei modificano  $Q^\pi(s, a)$ ?

A.A. 2020-2021

9/49



## SARSA



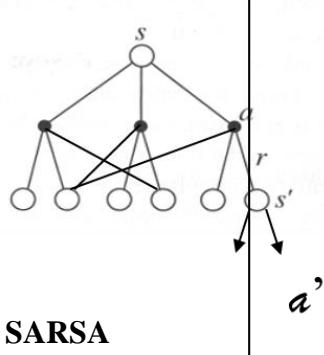
Non richiede conoscenze a priori dell'ambiente.

L'agente stima a partire da nulla (bootstrap).

Si dimostra che il metodo converge asintoticamente, stima  $Q^\pi(s, a)$  quando  $\alpha$  decresce dolcemente a 0 all'aumentare del numero di trial

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

Sample backup, single state,  
 $s_p$ , single action,  $a_p$ , single  
future state  $s' = s_{t+1}$



**State-Action-Reward-State-Action => SARSA**

A.A. 2020-2021

10/49



# Meccanismo di apprendimento nel RL



**Inizializzazione:** se l'agente non agisce sull'ambiente non succede nulla. Occorre specificare una policy iniziale.

**Ciclo dell'agente (le tre fasi sono sequenziali):**

- 1) Implemento una policy ( $\pi(s,a)$ )
- 2) Determino la Value function ( $Q^\pi(s,a)$ )
- 3) Aggiorno la policy.



# Background su SARSA



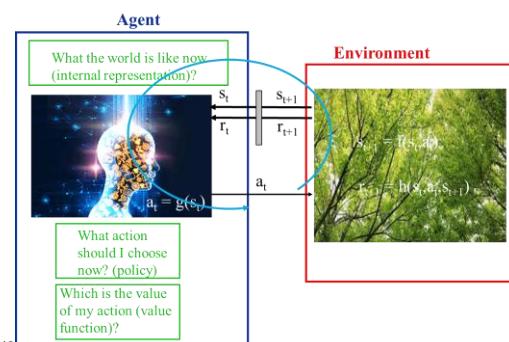
Al tempo  $t$  abbiamo a disposizione:

$$r_{t+1} = r' \text{ estratto (sampled) dalla distribuzione statistica: } R_{s \rightarrow s'|a_j}$$

$$s_{t+1} = s' \text{ estratto (sampled) dalla distribuzione statistica: } P_{s \rightarrow s'|a_j}$$

**Dopo la realizzazione di un evento, l'incertezza statistica scompare.**

- 1 Reward certo
- 1 Transizione certa  
vengono forniti dall'ambiente

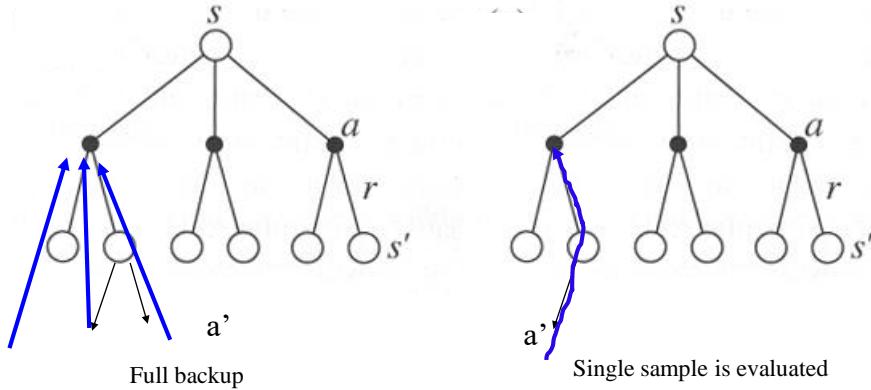




## Sample backup



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



State = s, Action = a, Reward (a un passo) = r, state = s', action = a'

A.A. 2020-2021

13/49



## SARSA Algorithm (progetto)



```

Q(s,a) = rand();           // ∀s, ∀a, eventualmente Q(s,a) = 0 - inizializzazione
Policy definita;          // Policy specificata, eventualmente stocastica
Repeat                      // for each episode
{
  s = s0;
  Repeat                  // for each step of the actual episode
  {
    a = Policy(s);         // policy deterministica o stocastica
    s_next = NextState(s,a); // Funzione non nota all'agente
    reward = Reward(s,snext,a);
    anext = Policy(snext);
    Q(s,a) = Q(s,a) + α [reward + γ Q(snext, anext) − Q(s,a)];
    s = snext;
  }                         // until last state
}                           // until the end of learning (convergence of Q(s,a) to true Q(s,a) ∀s, ∀a, for policy π(s,a) )

```

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

Come integrare i due passi?

A.A. 2020-2021

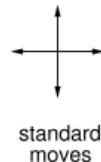
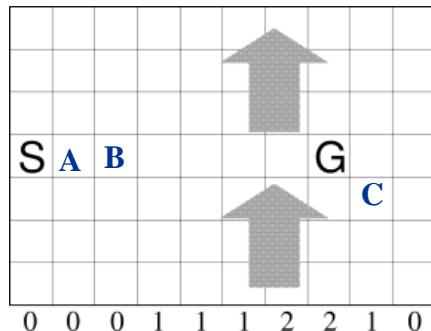
14/49



## Esempio



From Start, S, to Goal, G.



Stati = {caselle della griglia}

Stato iniziale = S

Terminal state = G

Azioni = {su, destra, giù, sinistra}

Reward = -1 tranne che quando  $s' = TS$  (reward = 0)

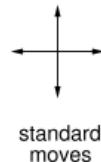
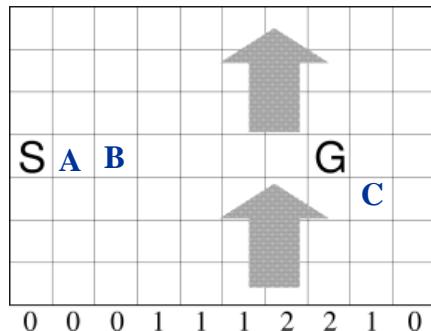
Upwards wind: somma uno spostamento verso l'alto allo spostamento dell'azione dell'agente



## Esempio



From Start, S, to Goal, G.



Upwards wind

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

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

$\pi(s,a)$  data.

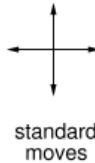
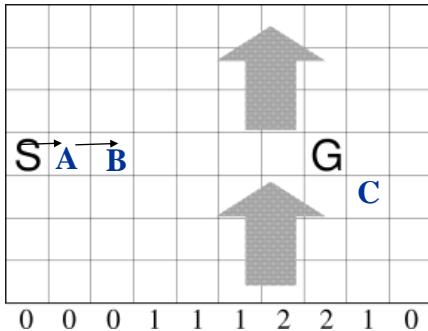
$\alpha = 0.5$

$\gamma = 1$

Vogliamo valutare  $\pi(s,a)$ .



## Esempio - risultato



$$\begin{aligned}\varepsilon &= 0.1 \\ \alpha &= 0.5 \\ \gamma &= 1\end{aligned}$$

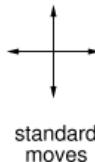
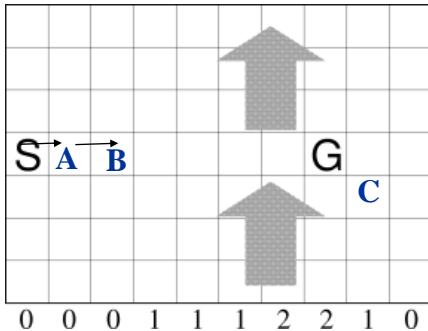
Correzione di Q ad un passo:

$$Q_{k+1}^{\pi}(S, \text{east}) = Q_k^{\pi}(S, \text{east}) + \alpha[r' + \gamma Q_k^{\pi}(A, \text{east}) - Q_k^{\pi}(S, \text{east})] = 0 + 0.5 [-1 + 1 \times 0 - 0] = -0.5$$

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



## Esempio - risultato



$$\begin{aligned}\alpha &= 0.5 \\ \gamma &= 1\end{aligned}$$

Correzione di Q ad un passo:

$$Q_{k+1}^{\pi}(A, \text{east}) = Q_k^{\pi}(A, \text{east}) + \alpha[r' + \gamma Q_k^{\pi}(B, \text{east}) - Q_k^{\pi}(A, \text{east})] = 0 + 0.5 [-1 + 1 \times 0 - 0] = -0.5$$

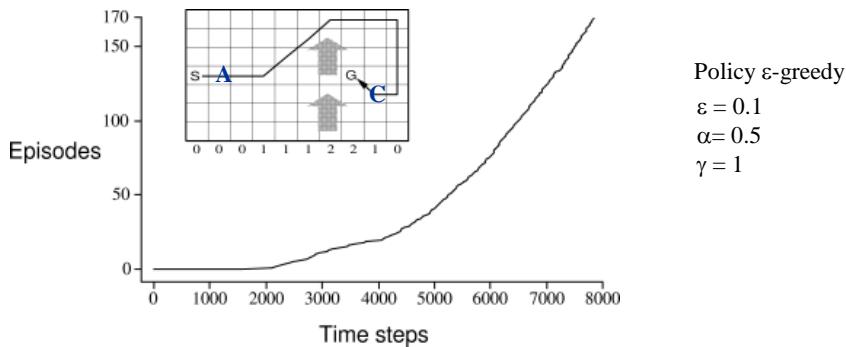
$$Q_{k+1}^{\pi}(C, \text{west}) = Q_k^{\pi}(C, \text{west}) + \alpha[r' + \gamma Q_k^{\pi}(G, \cdot) - Q_k^{\pi}(C, \text{west})] = 0 + 0.5 [0 + 1 \times 0 - 0] = 0$$

(NB c'è il vento verso l'alto di 1)

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



## Esempio - risultato

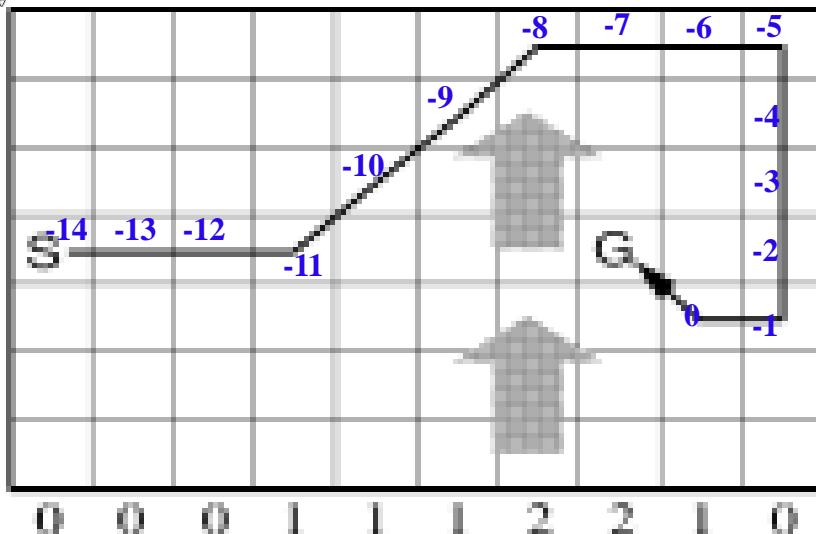


Aumentano gli episodi nello stesso intervallo di tempo, via via che trial vengono eseguiti.  
 All'inizio un trial richiede molto tempo per essere eseguito.

Non è il percorso ottimo (17 passi contro 15 passi)  
 E' il percorso cristallizzato.



## Esempio - valore di $Q^\pi(\cdot)$



We have estimated  $Q^\pi(s, a)$ . In most states we have better option. E.g. in S if we have better  $Q^\pi(S, a_{new})$  than moving East. This allows exploring different paths. We can change after having estimated  $Q^\pi(\cdot)$ .



# Sommario



SARSA

Q-learning

Esempi

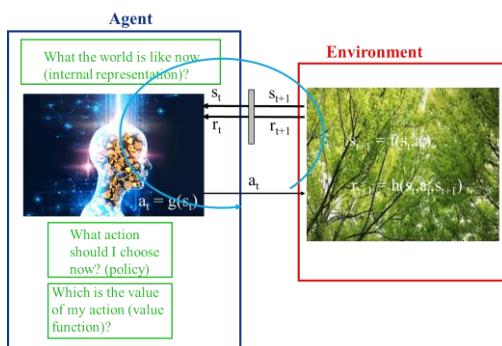


# Value Function?



La Value Function deriva dalla visione della Programmazione Dinamica.

Ma è proprio necessario conoscere esattamente la Value function?  
In fondo a noi interessa determinare la Policy.





## La policy in SARSA

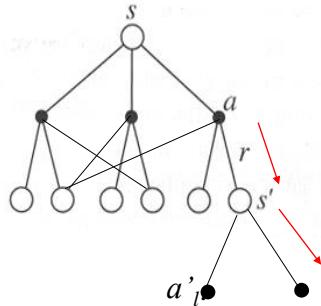


$$Q_{k+1}^{\pi}(s, a) = Q_k^{\pi}(s, a) + \alpha[r' + \gamma Q_k^{\pi}(s', a') - Q_k^{\pi}(s, a)]$$

1) Apprendiamo il valore di  $Q^{\pi}(\cdot)$  per una policy data (*on-policy*).

2) Dopo avere appreso la funzione  $Q^{\pi}(\cdot)$ , possiamo **modificare la policy**,  $\pi'(s,a)$ , in modo da migliorarla (**policy improvement**)

3) Dopo avere modificato la policy devo apprendere la nuova  $Q^{\pi'}(\cdot)$



A.A. 2020-2021

23/49

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



## Un ciclo di interazione



Agent

What the world is like now  
(internal representation)?



What action  
should I choose  
now? (policy)

Which is the value  
of my action (value  
function)?

Environment

$$s_{t+1} = f(s_t, a_t)$$

$$r_{t+1} = h(s_t, a_t, s_{t+1})$$

Per ora ci siamo concentrati sulla determinazione del valore

A.A. 2020-2021

24/49



# Sommario



SARSA

Q-learning

Esempi



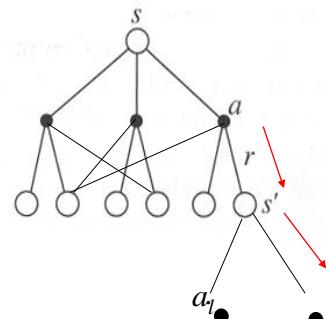
## Come apprendere Q: SARSA



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

- 1) Apprendiamo il valore di Q per una policy data,  $\pi$ , (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.



## Off-policy Temporal Difference: Q-learning

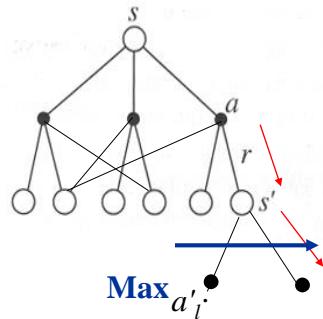


$$Q_{k+1}^{\pi}(s, a) = Q_k^{\pi}(s, a) + \alpha \left[ r' + \gamma \max_{a'} Q_k^{\pi}(s', a') - Q_k^{\pi}(s, a) \right]$$

Non imparo semplicemente la funzione  
valore  $Q^{\pi}(\cdot)$ , ma la funzione valore  
 $Q^{\pi^*}(\cdot)$  ottima.

In  $s$ , scelgo un ramo del grafo, e poi  
**decido** ad un passo come continuare,  
guardando il reward a lungo termine  
stimato per le diverse azioni.

Eventualmente cambio subito policy,  
 $a=\pi(s) \rightarrow a_{\text{new}}=\pi^*(s)$  senza aspettare di  
avere stimato esattamente  $Q^{\pi}(\cdot)$ .



A.A. 2020-2021

27/49

<http://borgheze.di.unimi.it/>



## Q-learning algorithm (progetto)



```

Q(s,a) = 0;           // ∀s, ∀a,
Policy data;          // deterministica o stocastica
Repeat                // for each episode
{
  s = s0; α = α * reduction_factor;      // decremento il coefficiente di aggiornamento α
  Repeat              // for each step of the single episode
  {
    a = Policy(s);           // eventualmente ε-greedy
    s_next = NextState(s,a); // non nota all'agente
    reward = Reward(s, snext, a);        // non nota all'agente
    anext_pol = PolicyGreedy(snext);   // on policy (greedy)
    anext = argmax(Q(snext, a);
    a
    if (anext_pol != anext)           // se esiste un'azione a' migliore
    {
      UpdatePolicy(snext, anext); }     // scelgo anext in snext da qui in poi
    endif;
    Q(s,a) = Q(s,a) + α [reward + γ Q(snext, anext) - Q(s,a)]; // aggiorno Q(s,a)
    s = snext;
    a = anext;                      // a = Policy(s = snext)
  } // until last state
} // until the end of learning (convergence of Q(s,a) to true Q(s,a) ∀s, ∀a, for policy π(s,a) )

```

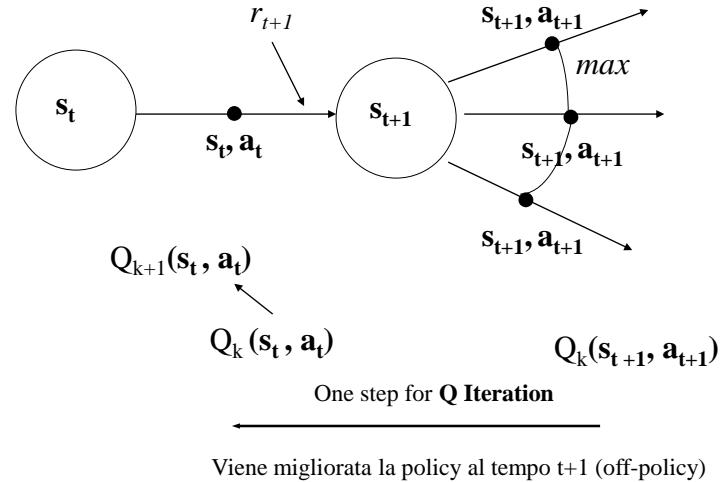
A.A. 2020-2021

28/49

<http://borgheze.di.unimi.it/>



## Rappresentazione grafica



A.A. 2020-2021

29/49

<http://borgheze.di.unimi.it/>

## Osservazioni



$\pi(s, a)$  sceglie l'azione ottima

$Q^\pi(s, a)$  converge al valore vero (della policy ottima)

Nella pratica la convergenza viene valutata sull'incremento uniforme di Q, ma anche sulla stabilità della policy identificata.

$$Q_{k+1}^\pi(s, a) = Q_k^\pi(s, a) + \alpha \left[ r' + \gamma \max_{a'} Q_k^\pi(s', a') - Q_k^\pi(s, a) \right]$$

L'operazione di max può essere un "hard" max o un "soft" max. Si possono considerare policy  $\epsilon$ -greedy.

A.A. 2020-2021

30/49



# Sommario



SARSA

Q-learning

Esempi



## Example 1 - Q Learning Update



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

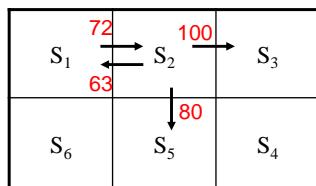
Modificati dalle slide di: Manuela Veloso, Reid Simmons, & Tom Mitchell, CMU

6 stati  $\{s_1, \dots, s_6\}$

Azioni: {su, destra, giù, sinistra}

Reward istantaneo = 0

Inizializzo  $Q(s,a)$  – in rosso.



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

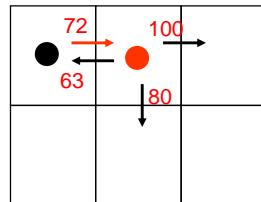
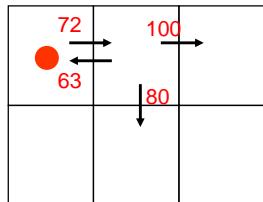


## Example 1 - Q Learning Update



$$\gamma = 0.9$$

$$s_{\text{ini}} = s_1$$



0 reward received in the transition.  $Q(.,.)$  initialized  $\neq 0$

Apprendimento della funzione valore Q. Versione Q-learning.  $Q(s_1, dx) = ?$

$s_1$	$s_2$	$s_3$
$s_6$	$s_5$	$s_4$

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

A.A. 2020-2021

33/49

<http://borgheze.di.unimi.it/>



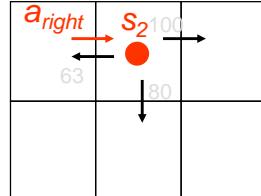
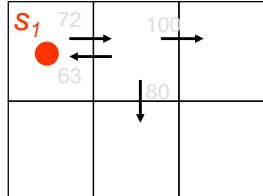
## Example 1 - Q Learning Update



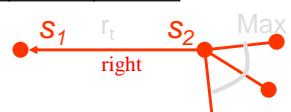
$$\gamma = 0.9$$

$$\alpha = 0.1$$

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



0 reward received in the transition



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

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

Correzione dell'azione in  $s_2$  da down a right

La correzione di  $Q(s_1, a_{\text{right}})$  va a 0 quando

$$Q(s_1, a_{\text{right}}) = 90$$

$$Q(s_2, a_{\text{down}}) = 80$$

$$Q(s_2, a_{\text{right}}) = 100$$

$$Q(s_2, a_{\text{left}}) = 63$$

A.A. 2020-2021

34/49

<http://borgheze.di.unimi.it/>

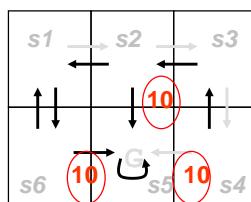


## Example 2: Q-Learning Iterations



- Stati:  $\{s_1, \dots, s_6\}$
- Azioni: {dx, sx, su, giù}
- Reward solo in alcune transizioni (in rosso e cerchiato).
- Stato iniziale:  $s_1$
- Initial selected policy: move clockwise;
- $Q(s,a)$  initially 0;

E.g. videogioco.  
In G rimango in G - loop



$$\begin{aligned}\alpha &= 1 \\ \gamma &= 0.8.\end{aligned}$$



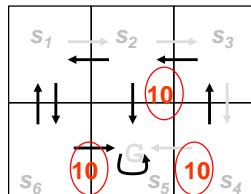
## Example 2: Q-Learning Iterations



- Start at upper left; Initial selected policy: move clockwise;  $Q(s,a)$  initially 0;  $\gamma = 0.8$ .
- Reward solo nelle transizioni.

$$Q_{k+1}^{\pi}(s_1, E) = Q_k^{\pi}(s_1, E) + \alpha \left[ r' + \gamma \max_{a'} Q_k^{\pi}(s_2, a') - Q_k^{\pi}(s_1, E) \right]$$

Reward  
istanteo in  
rosso e  
cerchiato



$$Q_{k+1}^{\pi}(s_1, E) = 0 + 1[0 + 0.8 \times 0 - 0] = 0$$

E.g. videogioco.  
In G rimango in G - loop

$Q(s_1, \text{East})$	$Q(s_2, \text{East})$	$Q(s_3, \text{South})$	$Q(s_4, \text{West})$
0			



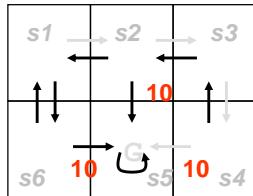
## Q-Learning Iterations - trial 1



- Start at upper left – move clockwise; table initially 0;  $\gamma = 0.8$ ;  $\alpha = 1$

$$Q_{k+1}^{\pi}(s, a) = Q_k^{\pi}(s, a) + \alpha \left[ r' + \gamma \max_{a'} Q_k^{\pi}(s', a') - Q_k^{\pi}(s, a) \right]$$

$$Q_{k+1}^{\pi}(s_3, S) = 0 + 1[0 + 0.8 \times 0 - 0] = 0$$



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

A.A. 2020-2021

37/49

<http://borgheze.di.unimi.it/>



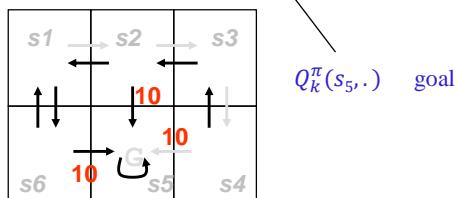
## Q-Learning Iterations - trial 1



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

$$Q_{k+1}^{\pi}(s_4, W) = Q_k^{\pi}(s_4, W) + \alpha \left[ r' + \gamma \max_{a'} Q_k^{\pi}(s_3, a') - Q_k^{\pi}(s_4, W) \right]$$

$$Q_{k+1}^{\pi}(s_4, W) = 0 + 1[10 + 0.8 \times 0 - 0] = 10$$



Q(S1,E)	Q(s2,E)	Q(s3,S)	Q(s4,W)
0	0	0	<b>10</b>

A.A. 2020-2021

38/49

<http://borgheze.di.unimi.it/>



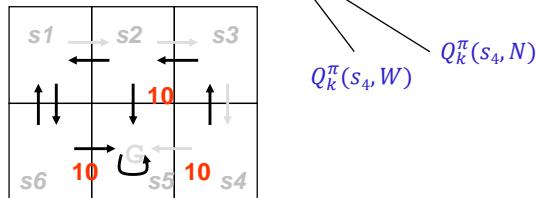
## Q-Learning Iterations - trial 2



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

$$Q_{k+1}^{\pi}(s_3, S) = Q_k^{\pi}(s_3, S) + \alpha [r' + \gamma \max_{a'} Q_k^{\pi}(s_4, a') - Q_k^{\pi}(s_3, S)]$$

$$Q_{k+1}^{\pi}(s_3, S) = 0 + 1[0 + 0.8 \{max, 10, 0\} - 0] = 8$$



Q(S1,E)	Q(s2,E)	Q(s3,S)	Q(s4,W)
0	0	0	10
0	0	<b>8</b>	

A.A. 2020-2021

39/49

<http://borgheze.di.unimi.it/>



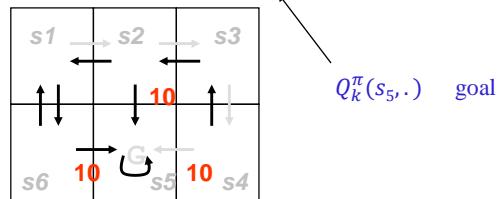
## Q-Learning Iterations - trial 2



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

$$Q_{k+1}^{\pi}(s_4, W) = Q_k^{\pi}(s_4, W) + \alpha [r' + \gamma \max_{a'} Q_k^{\pi}(s_3, a') - Q_k^{\pi}(s_4, W)]$$

$$Q_{k+1}^{\pi}(s_4, W) = 10 + 1[10 + 0.8 \times 0 - 10] = 10$$



Q(S1,E)	Q(s2,E)	Q(s3,S)	Q(s4,W)
0	0	0	10
0	0	8	10

A.A. 2020-2021

40/49

<http://borgheze.di.unimi.it/>



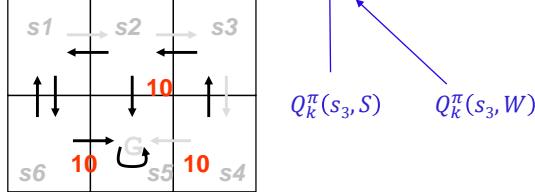
## Q-Learning Iterations - trial 3



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

$$Q_{k+1}^{\pi}(s_2, E) = Q_k^{\pi}(s_2, E) + \alpha [r' + \gamma \max_{a'} Q_k^{\pi}(s_3, a') - Q_k^{\pi}(s_2, E)]$$

$$Q_{k+1}^{\pi}(s_2, E) = 0 + 1 [0 + 0.8 \times \max_{a'} \{8, 0\} - 0] = 6.4$$



Q(S1,E)	Q(s2,E)	Q(s3,S)	Q(s4,W)
0	0	0	10
0	0	8	10
0	<b>6.4</b>		



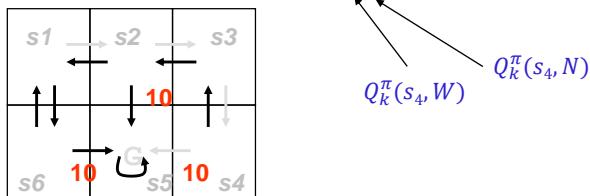
## Q-Learning Iterations - trial 3



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

$$Q_{k+1}^{\pi}(s_3, S) = Q_k^{\pi}(s_3, S) + \alpha [r' + \gamma \max_{a'} Q_k^{\pi}(s_4, a') - Q_k^{\pi}(s_3, S)]$$

$$Q_{k+1}^{\pi}(s_3, S) = 0 + 1 [0 + 0.8 \{ \max, 10, 0 \} - 0] = 8$$



Q(S1,E)	Q(s2,E)	Q(s3,S)	Q(s4,W)
0	0	0	10
0	0	8	10
0	<b>6.4</b>	8	10



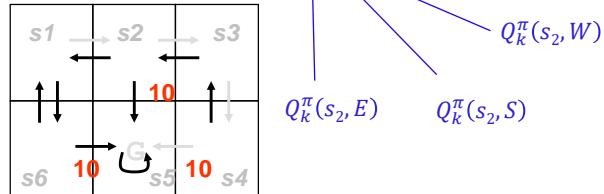
## Q-Learning Iterations – trial 4



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

$$Q_{k+1}^{\pi}(s_1, E) = Q_k^{\pi}(s_1, E) + \alpha [r' + \gamma \max_{a'} Q_k^{\pi}(s_2, a') - Q_k^{\pi}(s_1, E)]$$

$$Q_{k+1}^{\pi}(s_1, E) = 0 + 1 [0 + 0.8 \times \max_{a'} \{6.4, 0, 0\} - 0] = 5.12$$



Q(S1,E)	Q(s2,E)	Q(s3,S)	Q(s4,W)
0	0	0	10
0	0	8	10
0	6.4	8	10
<b>5.12</b>			

Potrei migliorare la policy: dovrei scegliere South in  $s_2$

<http://borgheze.di.unimi.it/>





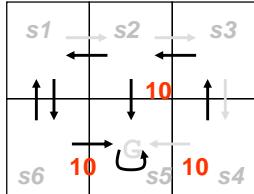
## Q-Learning Iterations: improving policy



- Start at upper left – move clockwise;  $\gamma = 0.8$ ;  $\alpha = 1$

$$Q_{k+1}^{\pi}(s_2, S) = Q_k^{\pi}(s_2, S) + \alpha [r' + \gamma \max_{a'} Q_k^{\pi}(s_5, a') - Q_k^{\pi}(s_2, S)]$$

$$Q_{k+1}^{\pi}(s_2, S) = 0 + 1[10 + 0.8 \times 0 - 0] = 8$$



$$Q_k^{\pi}(s_5, .)$$

Mossa  $\epsilon$ -greedy in  $s_2$  (invece che  $a = E$ , scelgo  $a = S$ , cambio azione): calcolo  $Q(s_2, S) = r + \gamma \max_{a'} \{Q(s_5, a')\} = 10 + 0.8 \times 0 = 10$

$Q(S1, E)$	$Q(s2, E)$	$Q(s2, S)$	$Q(s3, S)$	$Q(s4, W)$
0	0		0	10
0	0		8	10
0	6.4		8	10
5.12	6.4	8	8	10

uni.it\



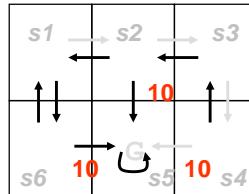
## Q-Learning Iterations: policy changed!



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

$$Q_{k+1}^{\pi}(s_1, E) = Q_k^{\pi}(s_1, E) + \alpha [r' + \gamma \max_{a'} Q_k^{\pi}(s_2, a') - Q_k^{\pi}(s_1, E)]$$

$$Q_{k+1}^{\pi}(s_1, E) = 0 + 1 [0 + 0.8 \times \max_{a'} \{6.4, 8, 0\} - 0] = 6.4$$



$$Q_k^{\pi}(s_2, E)$$

$$Q_k^{\pi}(s_2, S)$$

$$Q_k^{\pi}(s_2, W)$$

$Q(S1, E)$	$Q(s2, E)$	$Q(s2, S)$	$Q(s3, S)$	$Q(s4, W)$
0	0		0	10
0	0		8	10
0	6.4		8	10
6.4	6.4	8	8	10

uni.it\



# 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.

Utilizzo delle equazioni di Bellman

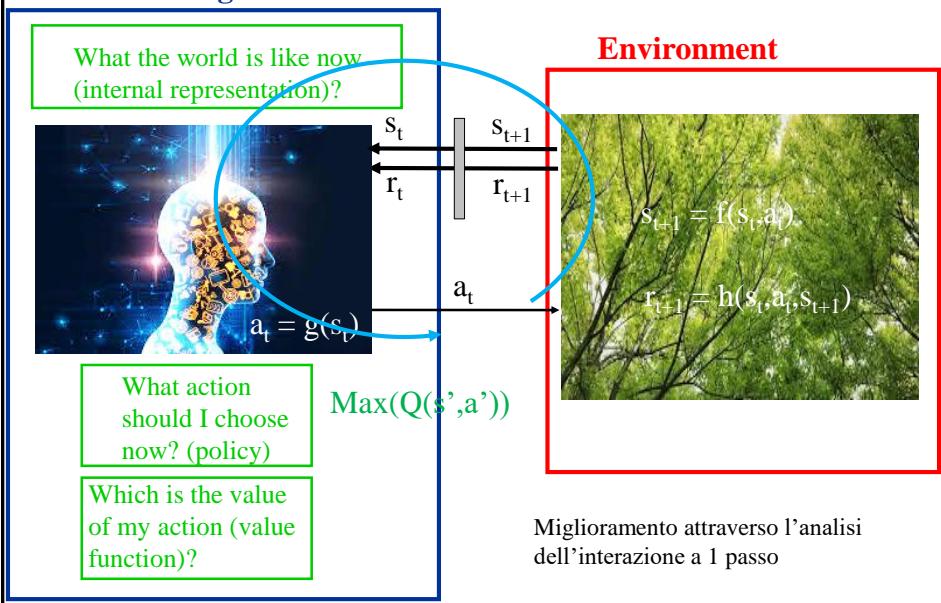
Utilizzo una "porzione" (sample) di esperienza per migliorare la policy.



# Un ciclo di interazione



Agent





# Sommario



SARSA

Q-learning

Esempi