

Sistemi Intelligenti Reinforcement Learning

Alberto Borghese

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

Dipartimento di Informatica

alberto.borghese@unimi.it

Chapter 2 – Barto Sutton



A.A. 2021-2022

1/51

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



Riassunto



- **Gli agenti ed il Reinforcement Learning**
- Apprendimento nel condizionamento classico
- Implementazione ricorsiva
- Caso non stazionario

A.A. 2021-2022

2/51

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



L'agente intelligente

- Inizialmente l'attenzione era concentrata sulla progettazione dei sistemi di "controllo". Valutazione, sintesi...
- L'intelligenza artificiale e la "computational intelligence" hanno consentito di spostare l'attenzione sull'apprendimento delle **strategie di controllo** e più in generale di comportamento (**planning, control, search, choice, prediction ...**).
- **Macchine dotate di meccanismi (algoritmi, SW), per apprendere queste strategie.**
- **RPA – Robot Process Automation**
- **Agenti intelligenti che operano scelte, controllano, pianificano, predicono ...**



Come acquisire l'intelligenza

L'agente **interagisce con l'ambiente** che fornisce **stimoli**.

Esperimenti di Ivan Pavlov (Nobel medicina nel 1904).



Quando un cane vede la ciotola del cibo inizia a salivare.



Si fa partire un metronomo poco prima della presentazione del cibo.



Dopo poco tempo il cane inizia a salivare appena vede/sente il metronomo.

Alla base del dog training. Perché non applicarlo anche alle macchine?





Osservazioni



Triggering of behaviour (or choice) that is most adequate to what?

Key is the **reward**. I cani sono molto golosi...

Lo stimolo condizionato funziona, perchè per gli esseri viventi (e la “lentezza” della risposta del sistema nervosa) è fondamentale **anticipare**.




Framework dell'apprendimento

- Un agente interagisce con l'ambiente.
- Può scegliere un'azione sull'ambiente tra un insieme continuo o discreto (qui il cane può mangiare, oppure può continuare a correre, ...).
- L'agente monitora l'ambiente (**input**). In questo caso il cane vede (e annusa) l'ambiente intorno, ma sente anche il metronomo.
- La scelta dell'azione è non banale e richiede un certo grado di “intelligenza”. Il cane «capisce» che mangiare dà più reward di continuare a correre.
- L'agente è in grado di modificare il proprio comportamento (dopo un po' di tentativi, il cane inizia a salivare (a prepararsi al pranzo) al suono del metronomo).

Un agente sceglie la propria azione in funzione del reward che ottiene dall'ambiente.

Il reward deve essere sufficientemente vicino nel tempo (associabile all'azione)






Apprendimento mediante RL



- L'agente deve scegliere un'azione, a (tra diverse azioni possibili discrete o continue).
- L'agente misura le ricompensa, r (reward) associate alla sua azione.



- L'agente deve scoprire autonomamente quale azione dà un reward massimo.
- Apprendimento all'interno di un singolo trial.



Reinforcement learning



Spesso si ha a disposizione solamente un'informazione qualitativa di ricompensa, detta **reward**, (a volte binaria, giusto/sbagliato successo/fallimento), puntuale fornita dall'ambiente.

Apprendimento con rinforzo è un apprendimento attraverso reward.

*L'informazione disponibile di ricompensa si chiama **segnale di rinforzo**. Non dà alcuna informazione su come aggiornare il comportamento dell'agente (e.g. i parametri), non è **istruttiva**. Non è possibile definire una funzione costo o un gradiente.*

*Il reward è un'informazione qualitative che dà una **valutazione**.*

Obiettivo: creare degli agenti "intelligenti" che abbiano una "machinery" per apprendere dalla loro esperienza, dalla valutazione ricavare delle istruzioni su come migliorare le azioni.

Ambiente viene considerate stocastico (non si conosce il suo comportamento e il suo comportamento non è stereo-tipato).



Reward



Il reward è il cibo!

Il cibo non dice al cane esplicitamente che è meglio mangiare di continuare a correre.

Il cibo dà una soddisfazione maggiore del correre.

Di conseguenza il cane, decide di mangiare invece di andare a correre in future.

Il reward non istruisce il cane su cosa fare (molto diverso dall'apprendimento supervisionato che vedremo: classificazione e regressione)

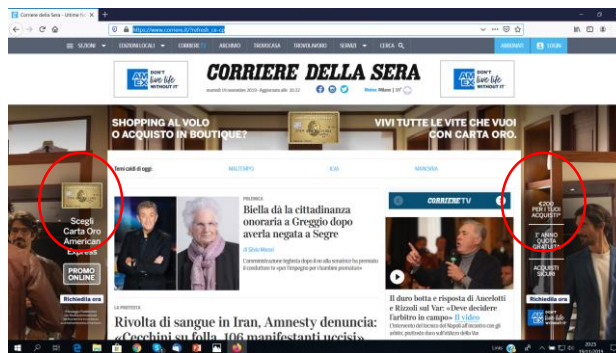
Il reward dà un'informazione qualitativa sull'azione, non istruttiva.

E' il cane che deve capire come utilizzare questa informazione qualitativa per migliorare le proprie azioni.



Esempio applicativo

Dove posizionare gli avvertimenti pubblicitari? Quanto valgono?




Ogni click sull'avvertimento è un rinforzo positivo.

L'agente prova diverse posizioni. Cerca di massimizzare il reward, cioè il numero di click.



Come migliorare l'azione

- L'agente deve scegliere un'azione, a (tra diverse azioni possibili discrete o continue).
- L'agente misura la ricompensa, r (reward) associata alla sua azione.



Evaluate the implemented solution.

- ◆ Success or fail? Adequate or not adequate?
- ◆ How much adequate? How to measure the success or failure of the performance?
- ◆ Optimization of the performance to create better agents.



Exploration vs Exploitation

Esplorazione (**exploration**) dello spazio delle azioni per scoprire le azioni migliori. Un agente che esplora solamente raramente troverà una buona soluzione.

Le azioni migliori vengono scelte ripetutamente (**exploitation**) perchè garantiscono ricompensa (**reward**). Se un agente non esplora nuove soluzioni potrebbe venire surclassato da nuovi agenti più dinamici.

Occorre non interrompere l'esplorazione.

Occorre un approccio statistico per valutare le bontà delle azioni.

Exploration ed exploitation vanno bilanciate. Come?

Qual è il comportamento ottimale?



Riassunto



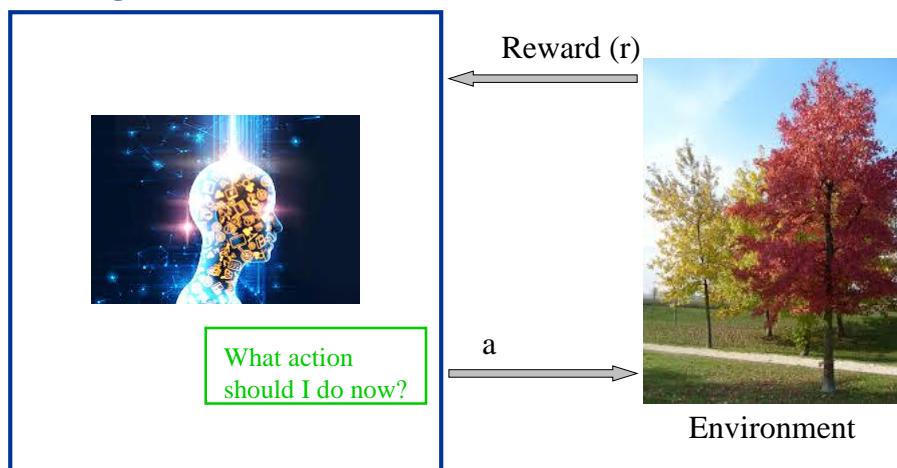
- Gli agenti ed il Reinforcement Learning
- **Apprendimento nel condizionamento classico**
- Implementazione ricorsiva
- Caso non stazionario



Schematic diagram of an agent



Agent






Il problema del "n-Armed bandit"



Situazione iniziale sempre uguale.

Scelta tra n azioni.

Il ciclo: azione + reward esaurisce l'episodio - trial)



La richiesta di scegliere viene ripetuta più volte nel tempo. Ogni volta si riparte dalla stessa situazione (**problema stazionario**).

La ricompensa è **stocastica** (e.g. slot machine).

Obiettivo: viene massimizzata la ricompensa a lungo termine.

Come selezionare l'azione che fornisce la massima ricompensa a lungo termine se non si conosce la statistica delle macchine?

A.A. 2021-2022

15/51

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



Slot machine stocastica




Il reward della slot machine è completamente definito dalla densità di probabilità associata alla macchina.

Si suppone la densità di probabilità del reward costante nel tempo e **NON NOTA**.

Per semplicità si suppone che la densità di probabilità sia descrivibile da una funzione analitica, ad esempio una Gaussiana. In questo caso la densità di probabilità è definita dai parametri della Gaussiana: media e standard deviation.

Posso estrarre +0.1 dalla Gaussiana verde e -1 dalla Gaussiana blu con probabilità diversa da zero.



A.A. 2021-2022

16/51

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



Come massimizzare la ricompensa



Consento all'agente di avere memoria.

Memorizzo il valore associato alle diverse azioni.

Posso ad un certo punto scegliere SEMPRE l'azione che mi ha dato la RICOMPENSA MAGGIORE.

Scelgo cioè l'azione GREEDY (Greedy = Goloso).

Sfruttiamo cioè la conoscenza raggiunta fino a quel momento (Exploitation).

Perché dovremmo scegliere un'azione che non appare la migliore (NON GREEDY)? Perché dovremmo esplorare altre azioni che non hanno dato la ricompensa maggiore?



Exploration



Perché esploriamo soluzioni diverse?

La ricompensa **non è deterministica**. Potremmo ottenere di più con altre azioni.

Quello che conta non è la ricompensa istantanea ma la somma delle ricompense ottenute. Voglio massimizzare il mio guadagno a lungo termine, ad esempio dopo avere premuto 1000 volte un braccio.

Occorre quindi mantenere un istinto ad esplorare azioni diverse.

Il bilanciamento di "exploration" e di "exploitation" è un compito complesso.



La Value Function e la scelta delle azioni



Razionale: associare un **valore** alle diverse azioni.

Il reward istantaneo non può rappresentare il valore perchè è 1 singolo campione estratto da una distribuzione statistica.

Devo cercare qualcosa di più significativo. Ad esempio il reward medio.

Posso scegliere come valore, il risultato della media campionaria: **funzione valore** (value function).

La funzione valore viene costruita dall'**agente** a partire dai reward istantanei forniti dall'**ambiente**. E' l'elemento chiave nell'apprendimento con rinforzo.



La Value Function e la scelta delle azioni



Posso selezionare n-azioni: $a = a_1 \dots a_n$. **Policy**.

In funzione dell'azione, la macchina mi darà un **reward**, $r(a_k)$.

Le posso valutare al tempo t come media campionaria dei reward associati a ciascuna azione, **funzione valore** (value function):

$$Q_{t(a_k)} = \frac{r_1(a_k) + r_2(a_k) + r_3(a_k) + \dots + r_N(a_k)}{N(a_k)}$$

Per il teorema del limite centrale il valore medio campionario dei rewar tende al valore medio della distribuzione dei reward per $N \rightarrow \infty$.

$$\lim_{N(a_k) \rightarrow \infty} Q_{t(a_k)} = Q^*(a_k) = \mu_k$$

Voglio scegliere a_k che massimizza il valore di a_k : $Q(a_k)$.

$Q(a_k)$ è un'approssimazione di μ_k .



Caratteristiche della Value Function



Value function calcolata come media campionaria:

$Q_t(a_k) \rightarrow Q^*(a_k)$ per $t \rightarrow \infty$

$Q_t(a_k) = 0$ $t = 0$. Nessuna stima disponibile.

Possibilità. Selezionare l'azione, a_k , che dà all'istante t , la massima Value Function al tempo t :

$$a^* : Q_t(a^*) = \max_{a_k} \{Q_t(a_k)\}$$

Così viene EXPLOITED la conoscenza accumulata, è una politica GREEDY.

Non vengono esplorate soluzioni alternative.

Come si può formalizzare un'alternativa?




Interazione rivista



- L'agente deve scegliere un'azione, a (tra diverse azioni possibili discrete o continue).
- L'agente misura le ricompense, r (reward) associate alla sua azione.
- Apprendimento all'interno di un singolo trial.

- L'agente costruisce una stima del valore di ciascuna azione, a_k , $Q(a_k)$.
- Prende una decisione in base a $Q(a_k)$, reward secondario, a lungo termine.






Analisi del problema

n-armed bandit problem: $n = 10$: $a = a_1, a_2, \dots, a_k, \dots, a_{10}$.

Il reward medio di ogni azione (verticale) viene selezionato secondo una Gaussiana con media zero e varianza 1.

La varianza di ogni reward è impostata a 1.



A.A. 202

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




Analisi del problema

Iniziamo prendendo l'azione 4: $a_{t=0} = a_4$. Supponiamo di ricevere un reward pari a 0.1.

$$Q(a_1) = Q(a_2) = Q(a_3) = Q(a_5) = Q(a_6) = Q(a_7) = Q(a_8) = Q(a_9) = Q(a_{10}) = 0 \quad Q(a_4) = 0.1$$

$$a^* : Q_t(a^*) = \max_{a_k} \{Q_t(a_k)\} \longrightarrow \text{Stuck on } a_4.$$



A.A. 2021-202

orgheese.di.unimi.it/



Politiche ϵ -Greedy

Scelgo l'azione che dà al Q_t massima (greedy) con probabilità $P = 1 - \epsilon$

Con probabilità piccola, ϵ , viene scelta un'azione diversa.

$$a^* : Q_t(a^*) = \max_{a_k} \{Q_t(a_k)\} \quad P = 1 - \epsilon$$

$$a \neq a^* \quad P = \epsilon$$

L'azione non greedy viene scelta con probabilità uniforme tra le n possibili azioni a disposizione.

$$Q_t(a_k) \rightarrow Q^*(a_k) \quad t \rightarrow \infty$$

Mantengo una certa capacità di esplorazione
Near-greedy policy.



Beyond ϵ -greedy: pursuit methods

Dopo ogni episodio, la probabilità di scegliere un'azione viene aggiornata:

- L'azione associata alla value function migliore **aumenta la probabilità** di essere prescelta.
- La probabilità di scegliere le altre azioni viene **decrementata**.
- Chiamo $\pi(a)$ la probabilità di scegliere l'azione a .

$$\pi_{t+1}(a^*_{t+1}) = \pi_t(a^*_{t+1}) + \beta [1 - \pi_t(a^*_{t+1})]$$

$$\pi_{t+1}(a) = \pi_t(a) + \beta [0 - \pi_t(a)] \quad \text{for } a \neq a^*_{t+1}$$

The preference for an action is always “**pursuing**” (inseguendo) the action that is greedy according to the current action-value estimate.

La probabilità di scegliere l'azione “migliore” aumenta con t (diminuisce l'esplorazione, aumenta l'exploitation).




Approccio generale della roulette



Le azioni vengono selezionate proporzionalmente ad una misura di performance nel momento attuale. Migliore essa è e più alta è la probabilità di selezione.

1. Si immagina una roulette di area unitaria, dove siano sistemate tutte le possibili azioni.
2. La dimensione del settore della roulette associata a ogni azione è proporzionale al valore di misura di performance di ciascuna azione.
3. La pallina viene lanciata all'interno della roulette e la possibilità che cada in una qualsiasi posizione è uniforme.
4. L'azione in corrispondenza della quale si ferma è quella selezionata



In questo esempio ci sono 4 possibili azioni.



Esempio: 10-armed testbed



n-armed bandit problem: $n = 10$: $a = a_1, a_2, \dots, a_k, \dots, a_{10}$.

Per ogni task (esperimento), eseguo 1000 volte la scelta di ciascuna azione:

$$t = t_1, t_2, \dots, t_{1000}$$


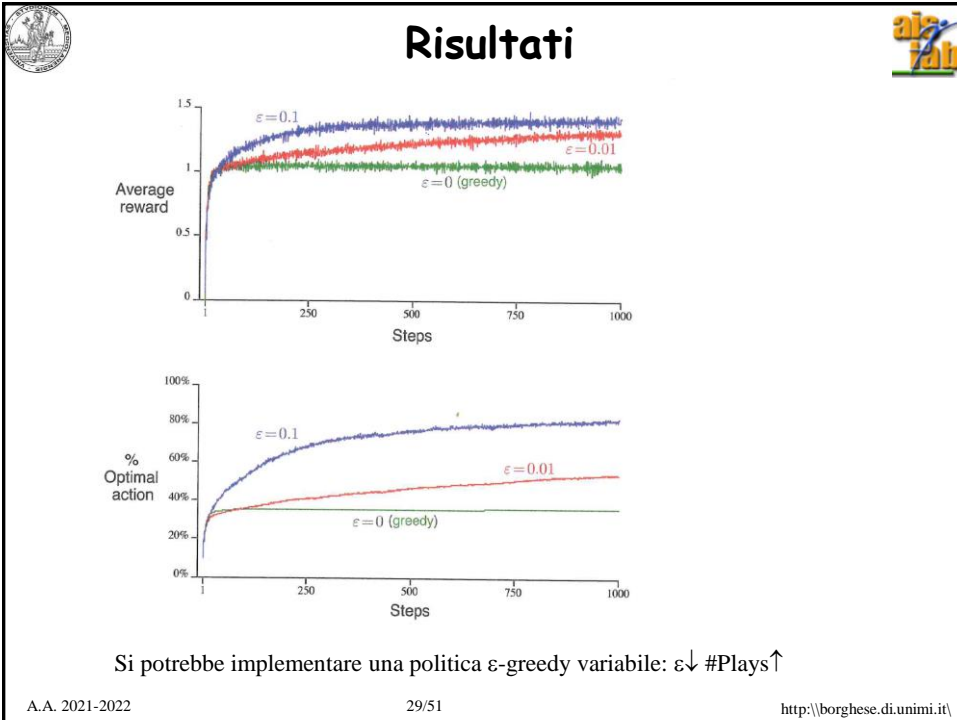
$$a = a(t_1), a(t_2), \dots, a(t_{1000})$$

$$r = r(a(t_1)), r(a(t_2)), \dots, r(a(t_{1000}))$$

Eseguo 2000 task (esperimenti).

Valuta la performance dopo le 1000 giocate di ogni task.

Viene fatta la media sulla performance (total reward) dopo 2000 task.





Domande



Supponiamo che la distribuzione da cui si sceglie il valore medio del reward abbia varianza nulla. Quale metodo funziona meglio: Greedy o ϵ -Greedy?

Supponiamo che la distribuzione da cui si sceglie il valore medio del reward abbia varianza maggiore (e.g. = 10). Cosa succede? Quale metodo si comporterebbe meglio?

In quali altre condizioni sarebbe utile avere esplorazione?



Riassunto



- Gli agenti ed il Reinforcement Learning
- Apprendimento nel condizionamento classico
- Implementazione ricorsiva
- Caso non stazionario



Calcolo ricorsivo di $Q(.)$

$$Q_i(a_k) = \frac{r_1 + r_2 + \dots + r_{N(a_k)}}{N(a_k)}$$

Occorre scegliere un algoritmo che calcoli $Q_i(.)$ con un piccolo carico computazionale e di memoria.

Supponiamo di fare Exploitation dell'azione a_k . Calcoliamo la media dei reward dopo N reward e la chiamiamo $Q_N(a_k)$. $Q_N(a_k)$ coinciderà con la media delle prime $N(a_k)$ ricompense associate all'azione a_k :

$$Q_{N(a_k)} = \frac{r_1(a_k) + r_2(a_k) + r_3(a_k) + \dots + r_{N(a_k)}}{N(a_k)}$$

Scegliendo ancora a_k , otteniamo il seguente valore di Q dopo $N+1$ reward:

$$Q_{N+1(a_k)} = \frac{r_1(a_k) + r_2(a_k) + r_3(a_k) + \dots + r_N(a_k) + r_{N+1(a_k)}}{(N+1)(a_k)}$$



Determinazione ricorsiva di Q_N

$$Q_N(a_k) = \frac{r_1 + r_2 + \dots + r_N}{N} \quad Q_{N+1}(a_k) = \frac{r_1 + r_2 + \dots + r_N + r_{N+1}}{N+1}$$

$$Q_{N+1} = \frac{r_1 + r_2 + \dots + r_N}{N+1} + \frac{r_{N+1}}{N+1} = \frac{Q_N N}{N+1} + \frac{r_{N+1}}{N+1} =$$

$$\frac{Q_N(N+1-1)}{N+1} + \frac{r_{N+1}}{N+1} = \frac{Q_N(N+1) - Q_N}{N+1} + \frac{r_{N+1}}{N+1} \Rightarrow$$

$$Q_{N+1} = Q_N - \frac{Q_N}{N+1} + \frac{r_{N+1}}{N+1} \quad \leftarrow \text{Dipende da } N+1$$

Non dipende da $N+1$

$$Q_{N+1} = Q_N + \frac{1}{N+1} (r_{N+1} - Q_N)$$



Osservazioni su Q_N



$$Q_{N+1} = Q_N + \frac{1}{N+1} (r_{N+1} - Q_N)$$

L'agente ragiona sul trial attuale.

Dipende solo da quantità:

- all'istante N abbiamo Q_N
- all'istante $N+1$ abbiamo $N+1, r_{N+1}$

NB N è il numero di volte in cui è stata scelta a_k , non è necessariamente coincidente con il tempo t !

Occupazione limitata della memoria.

Considero solo quello che avviene all'interno di un trial.

Il passato che mi interessa è riassunto da Q_N

Q_{N+1} rappresenta la media dei reward $\{r(a_k)\}$, tutti pesati $1/N+1$



Formulazione generale di Q_N



$$Q_{N+1} = Q_N - \frac{Q_N}{N+1} + \frac{r_{N+1}}{N+1} = Q_N + \alpha [r_{N+1} - Q_N] \quad \alpha = 1/(N+1)$$

$$Q_{N+1} = Q_N - \frac{Q_N}{N+1} + \frac{r_{N+1}}{N+1} = Q_N + \alpha [r_{N+1} - Q_N]$$

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

$$\text{NewEstimate} = \text{OldEstimate} + \text{StepSize} [\text{Target} - \text{OldEstimate}]$$

$$\text{NewEstimate} = \text{OldEstimate} + \text{StepSize} * \text{Error}$$

$$\text{StepSize} = \alpha = 1/(N+1)$$

α pesa il bilanciamento tra "innovazione" e "tradizione"

Osservazione:

Se $\alpha = 0$, conta solo la funzione valore (considera solo il passato).

Se $\alpha = 1$, Q_{N+1} assume il valore di Q_N (dimentica tutto il passato).



Esempio

$$Q_{N+1} = Q_N - \frac{Q_N}{N+1} + \frac{r_{N+1}}{N+1} = Q_N + \frac{1}{N+1}(r_{N+1} - Q_N)$$

$$\begin{array}{cccc} r_1 = 2 & r_2 = 3 & r_3 = 7 & r_4 = 2 \\ Q_1 = 2 & Q_2 = 2,5 & Q_3 = 4 & Q_4 = 3,5 \end{array}$$

$$Q_3 = Q_2 + \frac{1}{3}(r_3 - Q_2)$$

$$Q_3 = 2,5 + 1/3 (7 - 2,5) = 2,5 + 1,5 = 4,0$$

$$Q_4 = 4 + 1/4 (2 - 4) = 4 - 0,5 = 3,5$$



Caso stazionario

$$Q_{N+1} = \frac{r_1 + r_2 + \dots + r_N + r_{N+1}}{N+1}$$

Il peso di ciascun campione è pari a $1/(N+1)$

$$Q_{k+1} = \sum_{i=1}^{k+1} \frac{r_i}{N_{k+1}}$$

$$Q_{N+1} = Q_N - \frac{Q_N}{N+1} + \frac{r_{N+1}}{N+1}$$

Ogni nuovo campione viene pesato con $1/(N+1)$

$$Q_{N+1} = Q_N + \frac{1}{N+1}(r_{N+1} - Q_N)$$

Peso decrescente (con $1/(N+1)$) dei nuovi campioni

$$Q_{N+1} = Q_N + \alpha [r_{N+1} - Q_N] \quad \alpha = 1/(N+1)$$



Riassunto



- Gli agenti ed il Reinforcement Learning
- Apprendimento nel condizionamento classico
- Implementazione ricorsiva
- **Caso non stazionario**




Verso il caso non stazionario




Cosa succede se voglio calcolare il reward totale, pesando i vecchi campioni sempre meno?
 Media pesata, con peso decrescente nel tempo?

$$Q_t(a_k) = \frac{r_1(a_k) + r_2(a_k) + r_3(a_k) + \dots + r_N(a_k) + r_{N+1}(a_k)}{N+1(a_k)} = \sum_{i=1}^{N+1} \frac{r_i(a_k)}{N+1} \in \sum_{i=1}^{N+1} w_i r_i(a_k)$$



$$Q_{N+1} = Q_N + \frac{1}{N+1} (r_{N+1} - Q_N)$$

Calcolo la media in modo ricorsivo, in cui i pesi di tutti i campioni sono uguali (a $1/(N+1)$).



Somma pesata con $f(k)$ decrescente. Peso i reward "vecchi" poco

Somma: peso tutti i campioni allo stesso modo: $w_i = 1/(N+1)$



Caso non stazionario



$$Q_{N+1} = Q_N + \alpha [r_{N+1} - Q_N]$$

Al tempo $N+1$, ottengo r_{N+1}
 Q_0 è il valore a cui è inizializzata Q

Suppongo $\alpha = \text{cost} \rightarrow \alpha_{N+1} = \alpha \forall k \quad 0 \leq \alpha \leq 1$
In precedenza era $\alpha_{N+1} = 1/(N+1)$

$$\begin{aligned} Q_N &= Q_{N-1} + \alpha [r_N - Q_{N-1}] = \\ &= \alpha r_N + (1-\alpha)Q_{N-1} = \\ &= \alpha r_N + (1-\alpha)[\alpha r_{N-1} + (1-\alpha)Q_{N-2}] = \\ &= \alpha r_N + (1-\alpha)\alpha r_{N-1} + (1-\alpha)^2 Q_{N-2} = \end{aligned}$$

$$(1-\alpha)^0 \alpha r_N + (1-\alpha)^1 \alpha r_{N-1} + (1-\alpha)^2 \alpha r_{N-2} + \dots + (1-\alpha)^{N-1} \alpha r_1 + (1-\alpha)^N Q_0$$



Caso non stazionario



$$Q_N = \alpha r_N + (1-\alpha)Q_{N-1}$$

Al passo N , ottengo r_k
 Q_0 è il valore a cui è inizializzata Q

Suppongo $\alpha = \text{cost} \rightarrow \alpha_k = \alpha \forall k \quad 0 \leq \alpha \leq 1$

$$\begin{aligned} \alpha r_N + (1-\alpha)\alpha r_{N-1} + (1-\alpha)^2 \alpha r_{N-2} + \dots + (1-\alpha)^{N-1} \alpha r_1 + (1-\alpha)^N Q_0 = \\ (1-\alpha)^0 \alpha r_N + (1-\alpha)^1 \alpha r_{N-1} + (1-\alpha)^2 \alpha r_{N-2} + \dots + (1-\alpha)^{N-1} \alpha r_1 + (1-\alpha)^N Q_0 \end{aligned}$$

Per $r_i \quad 1 \leq i \leq N$

Per $(1-\alpha)^{N-i} \quad 1 \leq i \leq N$

$r_1 \rightarrow r_N$
 $(1-\alpha)^{N-1} \rightarrow (1-\alpha)^0$

$$Q_{N+1} = \sum_{i=1}^N \alpha (1-\alpha)^{N-i} r_i + (1-\alpha)^N Q_0$$



Osservazioni

$$Q_{N+1} = (1-\alpha)^N Q_0 + \sum_{i=1}^N \alpha(1-\alpha)^{N-i} r_i = (1-\alpha)^N Q_0 + \sum_{i=1}^N w_i r_i$$

$$w_i = \alpha(1-\alpha)^{N-i} \quad \alpha < 1$$

I reward **non** sono pesati tutti allo stesso modo: weighted average.

Il peso di ciascun campione decresce esponenzialmente a partire da $i = N$ (tempo presente, $w_N = \alpha$) fino a $i = 1$ (tempo iniziale $w_1 = \alpha(1-\alpha)^{(N-1)}$), secondo: $\alpha(1-\alpha)^{N-i} \quad \alpha < 1$

e.g. $\alpha = 0.8$, weights decrease from $0.8 \cdot 0.2^0 = 0.8$, to $0.8 \cdot (0.2)^{N-1}$, recency-weighted average.



Osservazioni

$$Q_{N+1} = Q_N + \alpha_{N+1} (r_{N+1} - Q_N)$$

L'agente ragiona sul trial attuale.

Dipende da solo da quantità:

- all'istante N : Q_N
- all'istante $N+1$: r_{N+1}

Q_N rappresenta la media pesata dei primi N reward

$$Q_{N+1} = \sum_{i=1}^N \alpha(1-\alpha)^{N-i} r_i + (1-\alpha)^N Q_0$$

Peso: esponenziale decrescente

$$\alpha_{N+1} = \text{costante} = \alpha \quad \forall N$$

$$Q_{N+1} = \sum_{i=1}^{N+1} \frac{1}{N+1} r_i$$

Peso: costante

$$\alpha_{N+1} = 1/(N+1)$$



Somma dei pesi dei reward è unitaria



$$Q_{N+1} = (1-\alpha)^N Q_0 + \sum_{i=1}^N \alpha(1-\alpha)^{N-i} r_i \quad \begin{array}{l} i=1 \rightarrow (1-\alpha)^{N-1} \\ i=N \rightarrow (1-\alpha)^0 \end{array}$$

Riscrivo considerando solamente i coefficienti.

Pongo $i = N - i$, la somma diventa da 0 a N-1:

$$\alpha \sum_{i=0}^{N-1} (1-a)^i + (1-\alpha)^N =$$

Aggiungo e sottraggo il termine $(1-\alpha)^N$ dentro la sommatoria:

$$\alpha \left(\sum_{i=0}^{N-1} (1-a)^i + (1-a)^N - (1-a)^N \right) + (1-\alpha)^N$$



Somma dei pesi dei reward è unitaria



$$Q_{N+1} = (1-\alpha)^N Q_0 + \sum_{i=1}^N \alpha(1-\alpha)^{N-i} r_i$$

$$\alpha \left(\sum_{i=0}^{N-1} (1-a)^i + (1-a)^N - (1-a)^N \right) + (1-\alpha)^N =$$

$$\alpha \left(\sum_{i=0}^{\overset{N}{\circlearrowleft}} (1-a)^i - (1-a)^N \right) + (1-\alpha)^N$$

$$\alpha \left(\frac{(1-a)^{N+1}-1}{(1-a)-1} - (1-a)^N \right) = \alpha \left(\frac{(1-a)^{N+1}-1}{-a} - (1-a)^N \right)$$



Somma dei pesi dei reward è unitaria



$$Q_{N+1} = (1-\alpha)^N Q_0 + \sum_{i=1}^N \alpha(1-\alpha)^{N-i} r_i$$

$$\alpha \left(\frac{(1-\alpha)^{N+1} - 1}{-\alpha} - (1-\alpha)^N \right) + (1-\alpha)^N =$$

Semplificando $-\alpha$

$$-(1-\alpha)^{N+1} + 1 - \alpha(1-\alpha)^N + (1-\alpha)^N =$$

Raccolgo $(1-\alpha)^N$

$$-(1-\alpha)^N(1-\alpha) + 1 + (1-\alpha)^N(1-\alpha) = 1 \quad \text{cvd}$$



Condizioni iniziali



$$Q_{N+1} = (1-\alpha)^N Q_0 + \sum_{i=1}^N \alpha(1-\alpha)^{N-i} r_i$$

Metodi ad $\alpha = 1/N_{k+1}$, Q_0 non viene utilizzato se non al primo passo, viene poi sostituito da Q_1 .

Metodi ad α costante, Q_0 conta sempre meno, ma la polarizzazione è permanente ($Q_0 \neq 0$).

Q_0 può essere utilizzato per fornire della **conoscenza a-priori** o per favorire l'esplorazione (e.g. transfer learning).

Come posso gestire una situazione in cui la slot machine cambia improvvisamente la sua densità di probabilità di reward?



Pseudo-codice per il calcolo di Q_k .



```
##### 1) Definizione delle variabili:
N_scelte = m; eps_greedy = 0.1; // epsilon dipende dal grado di greedy che voglio dare all'agente
## Variabili dell'agente
A = {1, 2, ..., m}; // Azioni possibili
Q = {Q1, Q2, ..., Qm} = 0; // Value function per ogni azione
N_azioni = {1, 2, ..., m}; // Numero di volte in cui è scelta l'azione j (e collezionato il reward associato).
## Variabili dell'ambiente. Date nella simulazione, misurate nell'ambiente nella realtà
// Inizializzo i parametri della distribuzione (stazionaria) dei reward per ogni azione
meanReward = [mean_1, mean_2, ..., mean_m]; stdReward = [std_1, std_2, ..., std_m];

##### 2) Ciclo di funzionamento
while (true)
{
  eps = rand_unif([0 1]); // Per politica epsilon-greedy
  // Exploitation
  [a_attuale Q_attuale] = SearchMax(Q); // Cerca l'azione ottima secondo Q
  // Exploration: se eps < eps_greedy, allora exploration
  if (eps < eps_greedy)
  // Devo trovare un'azione diversa da a_attuale -> a_ref
  {
    trovato = false; a_ref = a_attuale;
    while (trovato == false)
    {
      a_attuale = rand_unif(A);
      if (a_attuale != a_ref)
      {
        trovato = true; Q_attuale = Q(a_attuale);
      }
    }
  }
  // Eseguo l'azione a_attuale e misuro il reward ottenuto dalla slot machine
  r_attuale = rand_Gauss(meanReward(a_attuale), stdReward(a_attuale));
  // Update i dati per l'azione a_attuale: il numero di azioni e la value function Q
  N_azioni(a_attuale)++;
  Q(a_attuale) = Q(a_attuale) + 1/[N_azioni(a_attuale)] * (r_attuale - Q(a_attuale));
}
}
```

A.A. 2021-2022

49/51


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



RL su trial



- L'agente deve scegliere un'azione, a (tra diverse azioni possibili discrete o continue).
- L'agente misura la ricompensa, r (reward) associate alla sua azione.
- Apprendimento all'interno di un singolo trial.
- L'agente costruisce una stima del valore di ciascuna azione, a_k , $Q(a_k)$.
- Prende una decisione in base a $Q(a_k)$, reward secondario, a lungo termine.



A.A. 2021-2022

50/51

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



Riassunto



- Gli agenti ed il Reinforcement Learning
- Apprendimento nel condizionamento classico
- Implementazione ricorsiva
- Caso non stazionario