


# Invatare reimprospata

Catalin Stoean

# Ce este invatarea reimprospatata?

- ▶ Este **invatarea din interactiuni**.
- ▶ Avem un agent care
  - ▶ Invata si planifica permanent
  - ▶ Afecteaza mediul inconjurator
  - ▶ Are o multime de sarcini
  - ▶ Invata in urma a multiple mutari de genul incercare-si-eroare.




# Caracteristici ale invatarii reimprospatare

- ▶ *Invatarea reimprospata inseamna a invata cum sa actionezi pentru a maximiza o recompensa numerica.*
- ▶ Invatare din recompense numerice
- ▶ Interactionare cu sarcinile
  - ▶ Secvente de stari, actiuni si recompense
- ▶ Lumi incerte si nedeterministe
- ▶ Consecinte intarziate
- ▶ Invatare directionata catre tinta
- ▶ Echilibru intre explorare si exploatare


# Puncte de vedere

---

- ▶ Din punctul de vedere al agentului care invata:
  - ▶ Invatarea reimprospata este invatare din interactiunea cu mediul inconjurator prin incercare si eroare
  - ▶ Ex: ce recompensa primesc daca fac acest lucru?
- ▶ Invatarea reimprospata ca o unealta
  - ▶ Invatarea reimprospata din recompense si pedepse
  - ▶ Antrenarea calculatorului in acelasi fel in care antrenezi un caine
- ▶ Aplicabilitate: probleme cu interactiune continua
  - ▶ Robotica
  - ▶ Invatarea la animale
  - ▶ Planificare
  - ▶ Jocuri
  - ▶ Sisteme de control



# Invatare supervizata



- ▶ Pasul 1
  - ▶ Profesorul: Ce avem in imaginea 1, un caine sau o pisica?
  - ▶ Elevul: O pisica.
  - ▶ Profesorul: Nu, este un caine.
- ▶ Pasul 2
  - ▶ Profesorul: Imaginea 2 contine un caine sau o pisica?
  - ▶ Elevul: O pisica.
  - ▶ Profesorul: Da, este o pisica.
- ▶ Pasul 3 ...

Informatii de antrenare = scopul dorit




Eroare = (iesirea gasita – iesirea efectiva)

# Invatarea reimprospatata

- ▶ Pasul 1
  - ▶ Mediul: Te afli in starea 8. Alege intre actiunile A sau C.
  - ▶ Elevul: Actiunea C.
  - ▶ Mediul: Recompensa ta este de 100.
- ▶ Pasul 2
  - ▶ Mediul: Te afli in starea 17. Alege intre actiunile B sau F.
  - ▶ Elevul: Actiunea B.
  - ▶ Mediul: Recompensa ta este de 50.
- ▶ Pasul 3 ...

Informatii de antrenare = evaluari (“recompense” / “penalizari”)




Obiectiv: cat mai multe recompense posibile

# Invatarea reimprospata


## Formularea problemei

- ▶ Pornind din casuta cu patratul rosu, sa se ajunga la tinta (cercul verde).



## Dupa aplicarea invatarii reimprospata

- ▶ Urmele mai intense de verde simbolizeaza o recompensa mai mare pentru agent.



# Invatare reimprospata

---

- ▶ Agentul invata prin interactiunea cu mediul si prin observarea rezultatelor obtinute din aceste interactiuni.
  - ▶ Este vorba de “cauza si efect” si acesta este si modul in care noi ne formam cunoasterea aupa mediului pe parcursul vietii.
- ▶ Ideea de “cauza si efect” se traduce in pasii urmatori pentru un agent din cadrul invatarii reimprospatare:
  1. Agentul observa o stare de intrare
  2. Actiunea sa este determinata de o functie de luare de decizie (**o strategie**).
  3. Actiunea este indeplinita
  4. Agentul primeste o recompensa numerica de la mediu
  5. Informatia despre recompensa primita pentru starea/actiunea respectiva este retinuta

# Invatare reimprospatata

---

- ▶ Prin executarea de actiuni si observarea recompenselor obtinute, strategia folosita pentru a determina cea mai buna actiune pentru o stare poate fi imbunatatita.
- ▶ Daca suficiente stari sunt observate, o strategie de decizie optimala va fi generata si vom obtine un agent care actioneaza perfect in mediul sau.
- ▶ Asadar, agentul invata din recompensele primite de la mediu, fara sa existe vreo alta forma de supervizare in afara de propria strategie de a isi alege deciziile.
- ▶ Este *aruncat* in mediul sau si lasat sa se descurce singur, din propriile greseli si succese.

# Explorare si exploatare

---

- ▶ Daca agentul a incercat o actiune in trecut si a primit o recompensa potrivita, atunci repetarea acestei actiuni va reproduce aceeasi valoare.
  - ▶ Agentul **exploateaza** ceea ce stie pentru a primi recompensa.
- ▶ Pe de alta parte, agentul poate incerca alte posibilitati si ar putea obtine acolo recompense mai bune, deci **explorarea** este o tactica buna deseori.
- ▶ Fara un echilibru intre explorare si exploatare, agentul nu va invata eficient.

# Functii Valoare

---

- ▶ Sunt functii de perechi stare-actiune care estimeaza cat de buna o anumita actiune va fi intr-o stare data sau care este rezultatul asteptat pentru acea actiune.
- ▶  $V^\pi(s)$  – valoarea unei stari  $s$  sub strategia  $\pi$ .
  - ▶ Recompensa asteptata cand se incepe in  $s$ , urmand strategia  $\pi$ .
- ▶  $Q^\pi(s, a)$  – valoarea pentru luarea actiunii  $a$  in starea  $s$  sub strategia  $\pi$ 
  - ▶ Recompensa asteptata cand se incepe din  $s$ , se ia actiunea  $a$  si apoi se urmeaza strategia  $\pi$ .


# Invatarea bazata pe diferente temporale (DT)

- ▶ Se foloseste pentru a estima aceste functii valoare.
- ▶ Daca nu se estimeaza functia valoare, agentul trebuie sa astepte pana se primeste recompensa finala pentru a actualiza valorile pentru perechi stare-actiune.
- ▶ Pentru acest caz in care se merge pana la tinta pentru evaluare, se foloseste formula:
$$V(s_t) = V(s_t) + \alpha(R_t - V(s_t))$$
- ▶  $s_t$  este starea vizitata la momentul t
- ▶  $R_t$  – recompensa dupa momentul t
- ▶  $\alpha$  – parametru constant

# Invatarea bazata pe DT

$$V(s_t) = V(s_t) + \alpha(r_{t+1} + \gamma V(s_{t+1}) - V(s_t))$$

- ▶  $r_{t+1}$  este recompensa observata la momentul  $t+1$ .



# Strategii de selectare a actiunilor

---

- ▶ În funcție de strategie, se controlează echilibrul între explorare și exploatare.
  - ▶  **$\epsilon$ -greedy**
    - ▶ De cele mai multe ori, actiunea care întoarce cea mai mare recompensa estimata este selectata.
    - ▶ Cu o mica probabilitate,  $\epsilon$ , se alege o actiune în mod aleatoriu, independent de estimările pentru recompense.
  - ▶ **Softmax**
    - ▶ Se atasează o pondere pentru fiecare actiune relativ la estimarea stării în care se ajunge.
    - ▶ Alegerea actiunilor se face în mod aleatoriu, însă proporțional cu ponderea fiecărei actiuni.
    - ▶ Cele mai bune actiuni au sanse mari să fie selectate, iar cele mai proaste au sanse foarte mici.

# Algoritmi de invatare

## Invatarea Q

1. Se initializeaza  $Q(s, a)$  in mod aleatoriu sau cu zero
2. Repeta
  1. Initializeaza starea  $s$
  2. Repeta
    1. Alege actiunea  $a$  in functie de strategia aleasa ( $\epsilon$ -greedy sau Softmax)
    2. Executa actiunea  $a$ , observa  $r$  si  $s'$
    3. 
$$Q(s, a) = Q(s, a) + \alpha[r(s, a) + \gamma \max_{a'} Q(s', a') - Q(s, a)]$$
    4.  $s = s'$
  3. Pana cand s este stare terminala
3. Pana cand se intalneste conditia de oprire (un numar de iteratii)

- $\alpha$  – rata de invatare, cu valori in  $[0, 1]$ .
  - Daca luam  $\alpha = 0$ , valorile pentru  $Q$  nu se modifica, deci nu se invata nimic.
  - Daca luam  $\alpha = 0.9$ , invatarea are loc foarte rapid.
- $\gamma$  factorul de reducere cu valori tot in  $[0, 1]$ .
  - Face ca recompensele urmatoare sa conteze mai putin decat cele imediate.
- $\max_{a'}$  – recompensa maxima ce poate fi obtinuta in starea care urmeaza starii actuale, adica recompensa daca se ia cea mai buna actiune apoi.

# Algoritmi de invatare

## Invatarea Q

- ▶ Se initializeaza tabela de valori Q
- ▶ Se observa starea curenta  $s$
- ▶ Se alege o actiune  $a$  din starea  $s$ 
  - ▶ Actiunea se alege in functie de strategia folosita
- ▶ Se executa actiunea, se ajunge la o noua stare  $s'$  si se observa recompensa  $r$  care se obtine din starea  $s$ , daca se ia actiunea  $a$ .
- ▶ Se actualizeaza valoarea Q pentru starea curenta folosind recompensa obtinuta si cea maxima posibila pentru starea urmatoare (linia 2.2.3).
- ▶ Se trece la urmatoarea stare  $s'$ .

1. Se initializeaza  $Q(s, a)$  in mod aleator sau cu zero
2. Repeta
  1. Initializeaza starea  $s$
  2. Repeta
    1. Alege actiunea  $a$  in functie de strategia aleasa ( $\epsilon$ -greedy sau Softmax)
    2. Executa actiunea  $a$ , observa  $r$  si  $s'$
    3. 
$$Q(s, a) = Q(s, a) + \alpha[r(s, a) + \gamma \max_{a'} Q(s', a') - Q(s, a)]$$
    4.  $s = s'$
  3. Pana cand  $s$  este stare terminala
  3. Pana cand se intalneste conditia de oprire (un numar de iteratii)

- $\alpha$  – rata de invatare
- $\gamma$  factorul de reducere
- $\max_{a'}$  – recompensa maxima ce poate fi obtinuta in starea urmatoare

# Algoritmi de invatare

## Invatarea SARSA

---

- ▶ Nu se foloseste recompensa maxima a starii urmatoare ca la Q.
- ▶ In schimb, se alege o noua actiune (si astfel o noua recompensa se obtine) folosind aceeasi strategie.
- ▶ Numele “sarsa” vine de la faptul ca actualizările sunt realizate folosind tuplul  $Q(s, a, r, s', a')$ 
  - ▶  $s$  si  $a$  sunt starea si actiunea initiale
  - ▶  $r$  este recompensa obtinuta in starea  $s$  daca se ia actiunea  $a$
  - ▶  $s'$  si  $a'$  sunt noua pereche stare-actiune

# Algoritmi de invatare

## Invatarea SARSA

---

1. Se initializeaza  $\mathbf{Q}(\mathbf{s}, \mathbf{a})$  in mod aleator sau cu zero
2. Repeta
  1. Initializeaza starea  $\mathbf{s}$
  2. Repeta
    1. Alege actiunea  $\mathbf{a}$  in functie de strategia aleasa ( $\varepsilon$ -greedy sau Softmax)
    2. Alege actiunea  $\mathbf{a}'$  din  $\mathbf{s}'$  folosing aceeasi strategie
    3. 
$$\mathbf{Q}(\mathbf{s}, \mathbf{a}) = \mathbf{Q}(\mathbf{s}, \mathbf{a}) + \alpha[\mathbf{r} + \gamma \mathbf{Q}(\mathbf{s}', \mathbf{a}') - \mathbf{Q}(\mathbf{s}, \mathbf{a})]$$
    4.  $\mathbf{s} = \mathbf{s}'; \mathbf{a} = \mathbf{a}';$
  3. Pana cand s este stare terminala
3. Pana cand se intalneste conditia de oprire (un numar de iteratii)

# Exemplu

- ▶ Există 6 incaperi etichetate de la A la F.
- ▶ Agentul care va trebui să învețe din acest mediu este soarecele, care se află în imagine în încaperea D.
- ▶ Soarele este pus în diverse încaperi și trebuie să se adapteze în astfel încât să ajungă la cascaval și, evident, să nu ajungă la pisica.
- ▶ Cascavalul și pisica nu își pot schimba încaperile de care aparțin, dar soarele da.

Aplicați algoritmul bazat pe învățarea Q pentru aceasta problema.

*Rezolvarea  
poate fi gasita  
[aici](#).*

