

# Strojno učenje

## Uvod

Tomislav Šmuc

- Opservacije o SU
- Oblici SU: Tipologija i podjele
- Osnovni pojmovi

## Uloga strojnog učenja

- **Jezik računarstva (računalni jezici, algoritmi, baze podataka)**
  - najbolje je što imamo za opisivanje procesa (prirodnih ali i umjetnih sistema) spremanja, manipuliranja i korištenja podataka, informacija i znanja.
- **Algoritmi za procesiranje informacija predstavljaju:**
  - za biološke, kognitivne i socijalne znanosti ono što npr. algebra predstavlja za klasičnu fiziku.

## Konceptualne razlike u pogledu na svijet:

“Doba fizike”  
(1900-1950)

- Fokus na fizikalnu bazu svemira
- Naglasak na objašnjavanju svijeta (fenomena) fizikalnim procesima

“Doba računarstva”  
(1950- ....)

- Fokus na informacijskom (algoritamskom) objašnjavanju prirodnih fenomena
- Procesima koje podržavaju (inteligentna) bića: skupljanje, spremanje, procesiranje i korištenje podataka/informacija/znanja

## Zašto (proučavati) strojno učenje?

### Znanstveni izazovi:

- Kako uče životinje ili ljudi
- Zahtjevi da bi se nešto moglo naučiti: Precizni uvjeti pod kojima su neki ciljevi učenja ostvarivi
- Kako poboljšati učenje – aktivno i pasivno učenje
- Računalne arhitekture strojnog učenja

### Korisne primjene:

- Medicinska dijagnostika (EKG, EEG, mamografija)
- Otkrivanje novih zakonitosti u znanosti
- “Spam Filtering”, prijevare (npr. kreditne kartice), upadi u rač.sustave (npr. DOS attacks)
- pametno pretraživanje – sustavi za preporučivanje (google; amazon)
  - (searchpoint.si; )
- automatsko prevodenje govora & prepoznavanje govornika & razdvajanje više istovremenih govornika
- lociranje/identificiranje/praćenje objekata u slikama & na filmu & online (vidi DARPA challenge)



## Strojno učenje: usko vezane discipline

- Data mining – rudarenje podataka;
- Adaptivno procesiranje signala
- Probabilističko zaključivanje (Bayesove mreže)

## Razlika između statistike i strojnog učenja

- **Primijenjena statistika:**
  - obično primjenjujemo na "malim" skupovima podataka
  - uloga statističara je velika – računalo je pomoćni alat
- **Strojno učenje - naglasak je:**
  - na automatiziranju otkrivanja i korištenja pravilnosti u podacima;
  - karakteriziranju što je naučljivo i pod kojim uvjetima;
  - metodama koje garantiraju kvalitetu naučenih modela

## Što je učenje? = Memoriranje + zaključivanje

Zaključivanje

$$\forall x \text{Položio}(x, \text{Ispit}) \Rightarrow \text{Prijavio}(x, \text{Ispit})$$

Dedukcija

$$\text{Položio}(\text{Pero}, \text{Ispit})$$

---

$$\text{Prijavio}(\text{Pero}, \text{Ispit})$$

Indukcija

$$\text{Položio}(\text{Pero}, \text{Ispit}) \wedge \text{Prijavio}(\text{Pero}, \text{Ispit})$$

$$\text{Položio}(\text{Ivica}, \text{Ispit}) \wedge \text{Prijavio}(\text{Ivica}, \text{Ispit})$$

$$\neg \text{Položio}(\text{Kreso}, \text{Ispit}) \wedge \text{Prijavio}(\text{Kreso}, \text{Ispit})$$

$$\neg \text{Položio}(\text{Ante}, \text{Ispit}) \wedge \neg \text{Prijavio}(\text{Ante}, \text{Ispit})$$

.....

---

$$\forall x \text{Položio}(x, \text{Ispit}) \Rightarrow \text{Prijavio}(x, \text{Ispit}) ?$$

Abdukcija

$$\forall x \text{Položio}(x, \text{Ispit}) \Rightarrow \text{Prijavio}(x, \text{Ispit})$$

$$\text{Prijavio}(\text{Joža}, \text{Ispit})$$

---

$$\text{Položio}(\text{Joža}, \text{Ispit})$$

## Mogu li strojevi učiti bolje:

- Neki zadaci su najbolje definirani primjerima (npr. dijagnoza)
- Ako imamo velike količine podataka – one mogu kriti vrlo korisne pravilnosti ili prediktivne relacije (data mining)
- U realnim okruženjima karakteristike kompleksnih sustava (npr. promet u gradu) se brzo mijenjaju – software koji ima mogućnost brzog adaptiranja može povećati korisnost/sigurnost ....

## Oblici strojnog učenja – I podjela

### Nadzirano učenje (en. Supervised Learning)

- eksplizitna informacija o primjerima i vrijednosti njihove ciljne varijable (en. label)
- cilj: napraviti model koji će raditi predikcije na još neviđenim (novim) primjerima (klasificiranje objekata, predikcija prodaje, cijene ...)
  - Klasifikacija
  - Regresija
  - Predikcija – predviđanje (en. Forecasting) – vremenske serije

### Nenadzirano učenje - Unsupervised Learning:

- imamo samo primjere, bez ikakve anotacije ili povratne informacije o njihovoj kategorizaciji
- cilj : grupirati primjere, otkriti neku strukturnu pravilnost u podacima, projekcija podataka u niže-dimenzionalne prostore
  - Grupiranje - Clustering
  - Otkrivanje-detekcija iznimaka (Outlier detection)
  - Kompresija podataka

## Oblici strojnog učenja (nastavak)

### Učenje s podrškom (povratnom vezom - en. reinforcement learning):

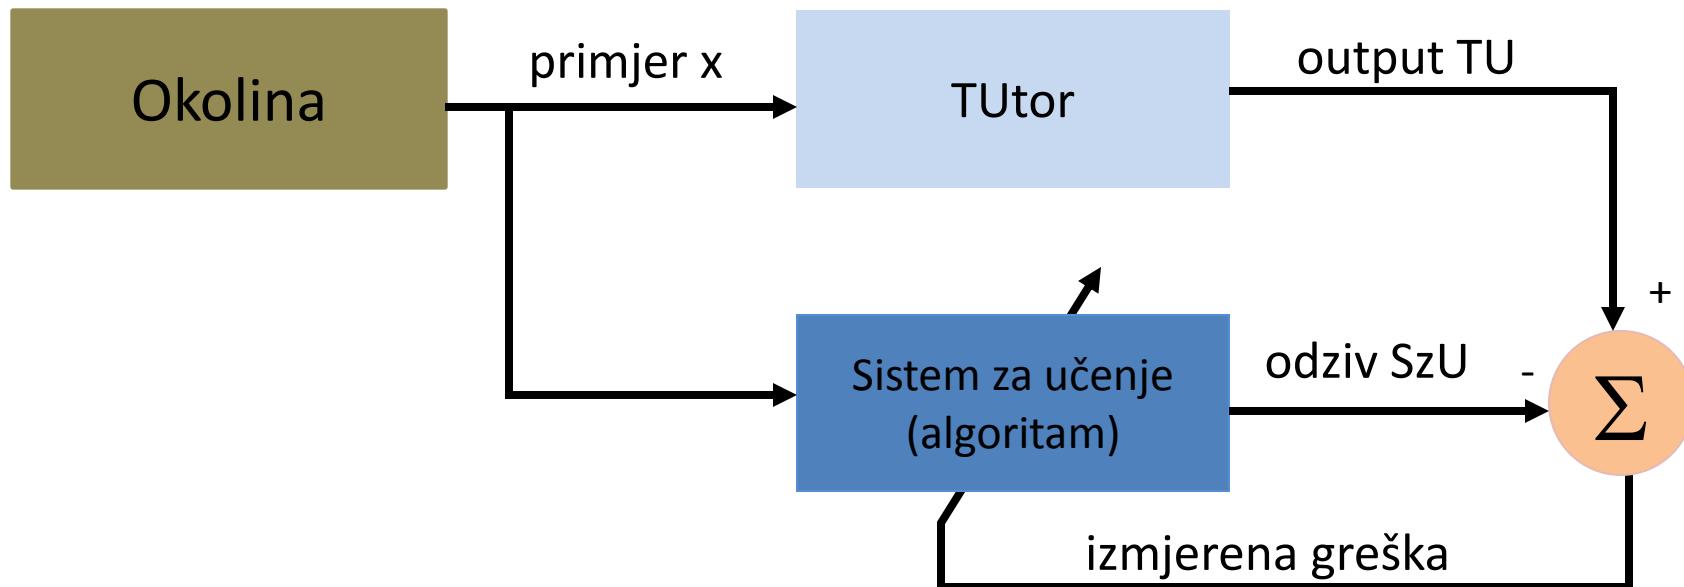
- dobivamo "nagradu" s odgodom ukoliko akcije predviđene našim modelom daju uspjeha
- nema eksplicitnog nadzora
- obično vezano uz učenje sekvenci akcija (igre, roboti!)

### Učenje skupa pravila

- iz danog većeg skupa mjerena ili transakcija, otkriti učestalo ponavljane uzorke mjerena (npr. asocijativna pravila)

## Nadzirano učenje (učenje uz učitelja/tutora)

- Znanje – svodi se na primjere ( $\text{input}_i, \text{output}_i = (x_i, y_i)$ )
- Cilj: minimizirati grešku između stvarnog outputa (učenik) i željenog outputa (učitelj)



## Nadzirano učenje (učenje uz učitelja/tutora)

### Klasifikacija:

- Output je kategorički
- Input može biti bilo što
- Cilj - da naučeni model odabire korektnu klasu

### Predikcija:

- klasifikacija/regresija
  - npr. vezana uz vremenski ovisne događaje
  - odrediti klasu/output koristeći nove ulazne sekvence (podatke) kao i neke prethodne sekvence/podatke i njihove klase/output na nekim prethodnim sekvencama

## Regresija - aproksimacija funkcija

Cilj – aproksimirati nepoznatu funkciju  $f_n(x)$

- tako da je preslikavanje  $F_a(x)$  realizirano sistemom za učenje približno isto kao i ono nepoznate funkcije  $f_n(x)$ :

$$|F_a(x) - f_n(x)| < \varepsilon \quad \forall x$$

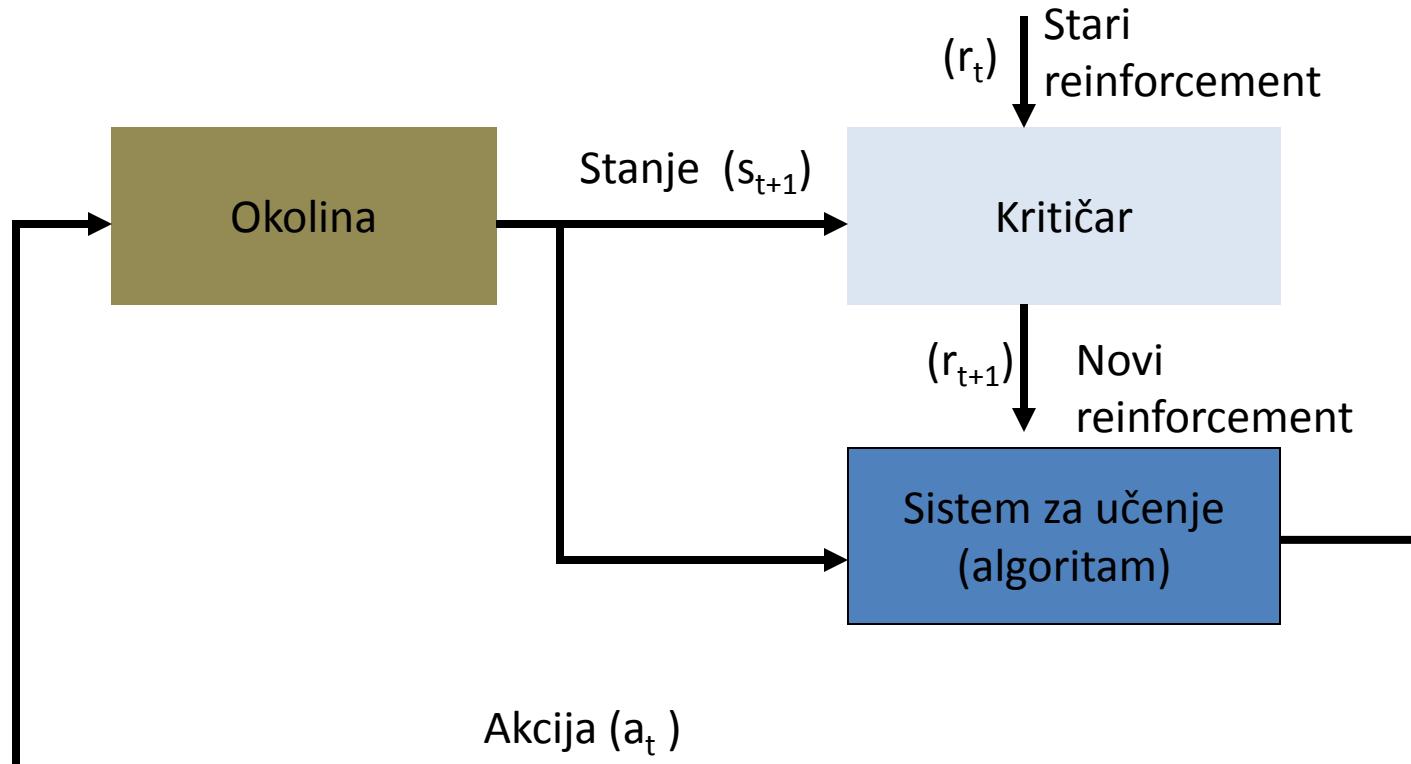
Primjer:

Opis input-output odnosa nekog nekog složenog sustava

- reakcija srca (ritam) – na različite podražaje
- raspodjela snage u jezgri reaktora – nakon spuštanja kontrolnih šipki

## Učenje podrškom - reinforcement learning – učenje niza akcija

- učenje – kroz interakciju s okolinom (ili barem simulacija interakcije)
- istraživanje odnosa stanja i akcija
- povratna veza (feed-back) kroz odgođeni primarni reinforcement
- Cilj: maksimiziranje akumuliranih budućih “reinforcements”



## Kontrola procesa – učenje funkcije kontrole

- Podesiti parametre nekog kontrolnog sustava tako da na kraju vodi proces na optimalan način



## Primjeri učenja kontrole (Reinforcement Learning)

- Navigacija robota
- Učenje akcija koje maksimiziraju/optimiraju output nekog pogona (tvornice), procesa trgovanja dionicama na burzi....
- Učenje poteza u igri (šah, backgammon)

### Karakteristike ovih problema:

- Odgođeno nagradjivanje umjesto instantnog - za dobre akcije (tzv. temporal credit assignment problem)
- Nema pravog nadzora – supervizije procesa učenja (primjeri su u obliku stanje, akcija)
- Postoji potreba za aktivnim istraživanjem prostora stanja i akcija

## Nenadzirano učenje

- nema učitelja niti kritičara
- samo-organizirajuća svojstva
- mjera dobrote/kvalitete – neovisna o zadatku
- potrebno je naći pravilnosti u podacima – otkriti klase automatski – te otkriti što one znače ili predstavljaju!



## Vrlo poopćena definicija strojnog učenja

Poboljšati kvalitetu izvršavanja zadatka  $t$ ,

s obzirom na definiranu mjeru uspješnosti  $q$ ,

na osnovu dostupnog iskustva (znanja i podataka)  $e$

### Primjeri

$t$ : igranje šaha (povlačenje pravih poteza)

$q$ : omjer dobivenih i izgubljenih igara

$e$ : igranje igara protiv samog sebe

$t$ : prepoznavanje slova u tekstu

$q$ : postotak točno prepoznatih slova

$e$ : baza slika sa ručno napisanim tekstovima (pixel po pixel)

$t$ : određivanje funkcije gena

$q$ : postotak točno "anotiranih" funkcija za gene s poznatom funkcijom

$e$ : dostupne baze ekspertno/eksperimentalno anotiranih gena (bioinformatika)

$t$ : kome ponuditi novu policu osiguranja

$q$ : postotak točno određenih kandidata iz baze poznatih primjera

$e$ : baza podataka o klijentima osiguravajućeg društva

\*

## Stvaranje modela iz skupa primjera

1. Pretpostavka: postoji distribucija vjerojatnosti  $p(\mathbf{x}, \mathbf{y})$  čiji pravi oblik neznamo

Obično na raspolaganju imamo tek (konačan) skup primjera (parova  $\mathbf{x}$  i  $\mathbf{y}$ ) (obično uz određeni "šum" ili greške):

$$\{\mathbf{x}_1, y_1; \dots; \mathbf{x}_n, y_n; \dots; \mathbf{x}_N, y_N\}$$

Primjeri iz skupa su iid (independently and identically distributed)

2. Koristeći samo  $\{\mathbf{x}_1, y_1; \dots; \mathbf{x}_n, y_n; \dots; \mathbf{x}_N, y_N\}$  generiramo model  $M$  koji za neki  $\{\mathbf{x}_n\}$  daje  $\{z_n\}$  (po mogućnosti tako da je što češće  $z_n = y_n$ , t.j. da model što manje grijesi)
3. Zamislimo situaciju da je neki novi skup primjera  $\{\mathbf{x}_k, y_k\}$  "izvučen" iz distribucije  $p(\mathbf{x}, \mathbf{y})$ . Naš model koristimo za određivanje  $\{z_k\}$ . (ukoliko znamo stvarni  $y_k$  možemo odrediti i grešku na novom, tzv. testnom skupu)

## Osnovni problemi u ovom postupku:

- Koji algoritmi i u kojim uvjetima dobro aproksimiraju funkcije i pod kojim uvjetima?
- Kako broj primjera utječe na točnost modela?
- Kako kompleksnost reprezentacije mogućih modela/hipoteza utječe na točnost?
- Kako šum ili greške utječu na točnost?
- Koji su teoretski limiti “naučljivosti”?

## Generalizacija

Osnovni problem train/test sampliranja i učenja:

- opasnost da ćemo dobiti model koji odlično “radi” samo na podacima na kojima je *istreniran*

=> overfitting (ili suprotno od generalizacije)

- učenje primjera napamet
  - = savršen rezultat na training skupu
  - = slučajno pogađanje na novim primjerima

**Generalizacija ~ sposobnost dobre predikcije na novim primjerima !**

## Kapacitet = kompleksnost (prostora) hipoteza

Hipoteza induktivnog učenja – generalizacija je moguća

Ako naš model dobro radi na većini podataka na kojima je treniran, te ako nije prekompleksan – vjerojatno je da će dobro raditi i na novim podacima

(da - ako su generirani iz iste distribucije kao i podaci za treniranje...)

Ova empirijska izjava je inače prilično dobro formalizirana u više desetaka godina istraživanja u području teorije strojnog učenja...

(SRM&VC-dimension, PAC learning, Occam's razor, MDL....)

## Induktivna pristranost (inductive bias)

Posljedica osnovne hipoteze induktivnog učenja:

generalizacija je moguća samo ako unaprijed radimo neke pretpostavke o konačnom izgledu hipoteze odnosno ako je kompleksnost mogućih hipoteza ograničena !

**algoritam/učenik koji nema ugrađenu induktivnu pristranost ne može generalizirati !**

## Što čini metodu/algoritam strojnog učenja ?

- **reprezentacija modela/ciljne funkcije**  
(linearna funkcija, polinom, neuralna mreža....)  
(sa nepoznatim vrijednostima slobodnih parametara)
- **algoritam pretraživanja/optimizacije**  
(strojno učenje = pretraživanje/optimizacijski problem)
- **metoda procjene greške** na “neviđenim” primjerima –  
skalarna **funkcija cilja** kojom ćemo kvantificirati kako  
dobro radi/generalizira naš naučeni model

---

Cilj: podesiti vrijednosti parametara ciljne funkcije modela tako  
minimiziramo vrijednost funkcije cilja

## Generalni oblik funkcije cilja

$$\phi(\mathbf{X}, \mathbf{Y}; \mathbf{w}) = L(\mathbf{X}, \mathbf{Y} | \mathbf{w}) + R(\mathbf{w})$$

$\mathbf{w}$  – parametri modela

$L(\mathbf{X}, \mathbf{Y} | \mathbf{w})$  – mjera greške modela (loss function)

$R(\mathbf{w})$  – funkcija kojom se penalizira kompleksnost modela

- oblik  $\phi(\mathbf{X}, \mathbf{Y}; \mathbf{w})$  opet govori o tome da želimo postići što manju grešku na skupu za učenje ( $L$ ) ali isto tako da to želimo postići sa što jednostavnijim modelom  $\mathbf{w}$  !