Strojno učenje
Uvod

Tomislav Šmuc

Sadržaj – Uvod u Strojno Učenje

- Strojno učenje
- Oblici Strojnog učenja: 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**.

Jučer i danas:

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

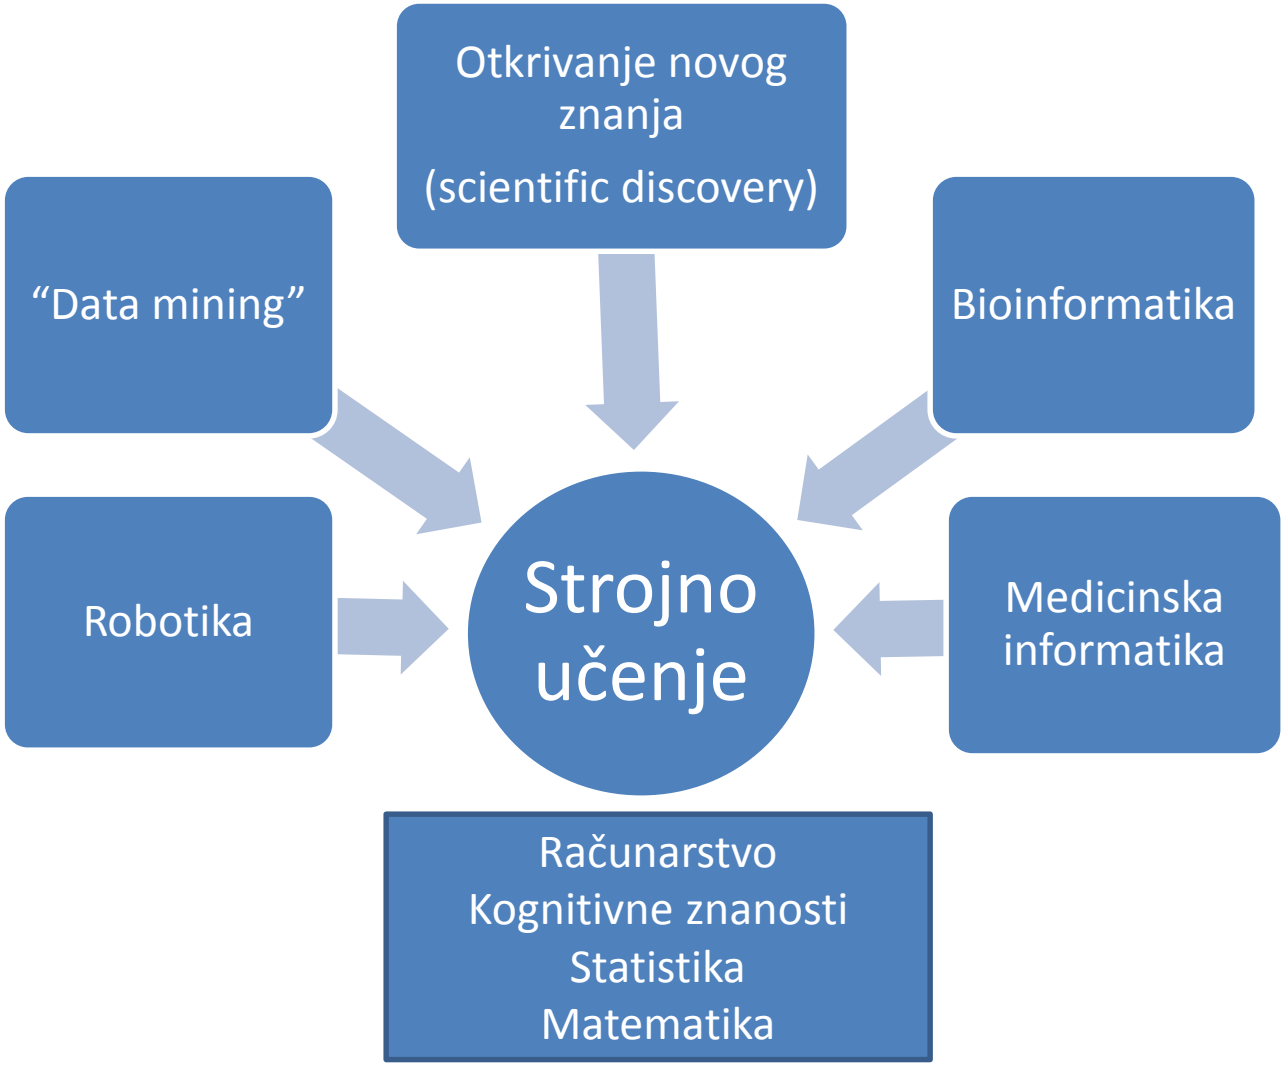
Otkrivanje novog znanja
(scientific discovery)
"Data mining"
Bioinformatika
Robotika
Strojno učenje
Medicinska informatika
Računarstvo
Kognitivne znanosti
Statistika
Matematika

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 ”manjim” 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 $\forall x$ *Položio (x,Ispit)* $\Rightarrow$ *Prijavio(x, Ispit)*

Dedukcija ⇒

Položio(Pero, Ispit)

Prijavio (Pero, Ispit)

Indukcija ⇒

Položio(Pero, Ispit)^ Prijavio (Pero, Ispit)
Položio(Ivica, Ispit)^ Prijavio (Ivica, Ispit)
¬ Položio(Kreso, Ispit) ^ Prijavio (Kreso, Ispit)
¬ Položio(Ante, Ispit) ^ ¬ Prijavio (Ante, Ispit)
.....

$\forall$ *x Položio (x,Ispit)* $\Rightarrow$ *Prijavio(x, Ispit) ?*

Abdukcija ⇒

$\forall$*x Položio (x,Ispit)* $\Rightarrow$ *Prijavio(x, Ispit)*
Prijavio(Jože, Ispit)

Položio (Jože,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)
- eksplicitna 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 mjerenja ili transakcija, otkriti učestalo ponavljane uzorke mjerenja (npr. asocijativna pravila)

Nadzirano učenje (učenje uz učitelja/tutora)

- Znanje – svodi se na primjere ($input_i$,$output_i$) = (x_i,y_i)
- Cilj: minimizirati grešku između stvarnog outputa (učenik) i željenog outputa (učitelj)

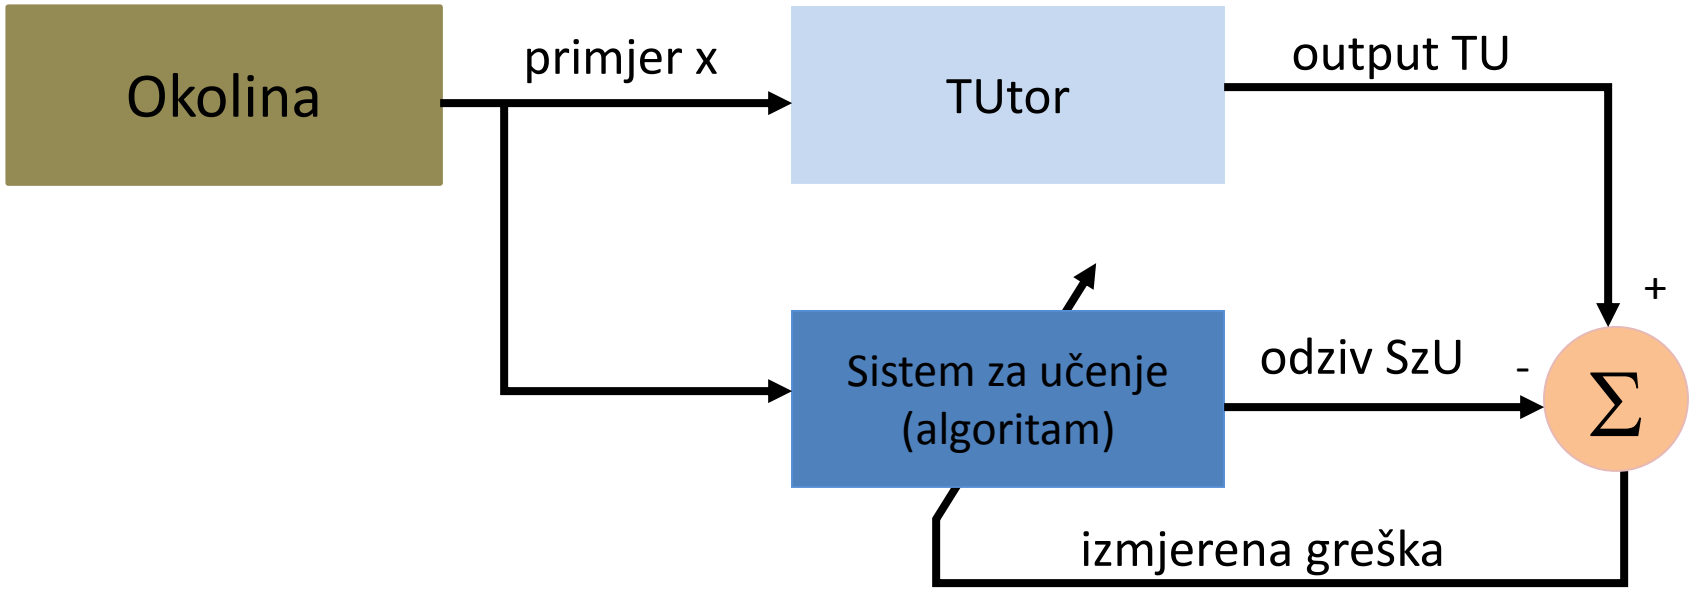

Nadzirano učenje (učenje uz učitelja/tutora)

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 $f_n(\mathbf{x})$

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

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

Primjer:

Opis input-output odnosa nekog složenog sustava:

- raspodjela snage u jezgri reaktora – nakon spuštanja kontrolnih šipki
- simuliranje ponašanja nekog elektroničkog sklopa na ulazni signal
- reakcija srca (ritam) – na različite podražaje

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 „pojačanja” (en. Reinforcements)

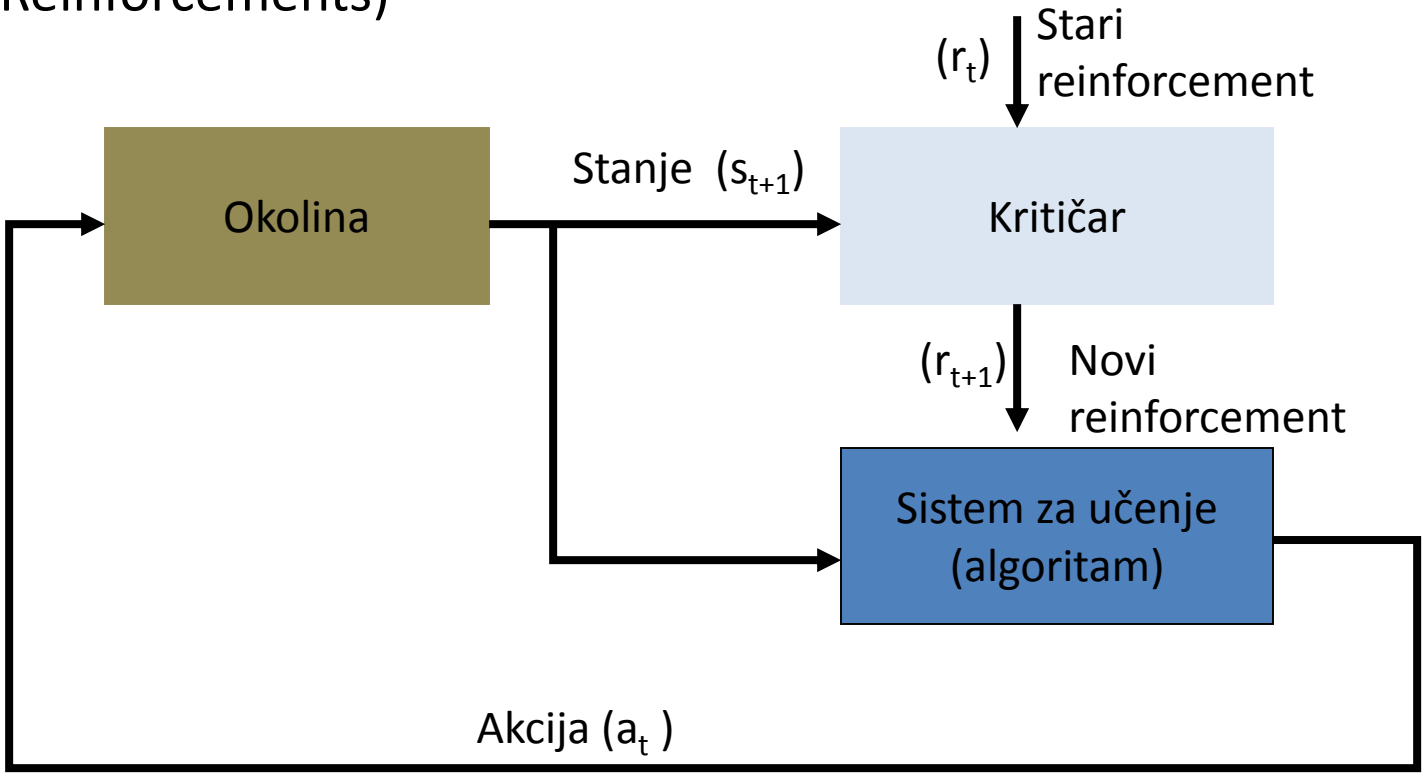

Kontrola procesa – učenje funkcije kontrole

- 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, go)

Karakteristike ovih problema:

- Odgođeno nagrađivanje 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!

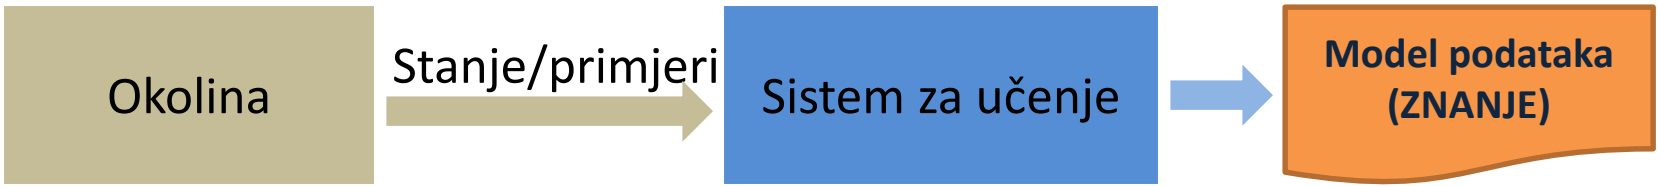

Vrlo poopćena definicija strojnog učenja

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(**x**, y) čiji pravi oblik neznamo

   Obično na raspolaganju imamo tek (konačan) skup primjera (parova **x** i y) (obično uz određeni "šum" ili greške):

   $\{\boldsymbol{x}_1, y_1; \ldots; \boldsymbol{x}_n, y_n; \ldots; \boldsymbol{x}_N, y_N\}$

   Primjeri iz skupa su iid (independently and identically distributed)

2. Koristeći samo $\{\boldsymbol{x}_1, y_1; \ldots; \boldsymbol{x}_n, y_n; \ldots; \boldsymbol{x}_N, y_N\}$ 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 griješi)

3. Zamislimo situaciju da je neki novi skup primjera $\{\mathbf{x}_k, y_k\}$ "izvučen" iz distribucije p(**x**, 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...)

formaliziracija kroz 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

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

w – parametri modela
L (**X**,Y|**w**) – mjera greške modela (loss function)
R (**w**) – funkcija kojom se penalizira kompleksnost modela

- oblik $\phi(\mathbf{X},Y;\mathbf{w})$ 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 **w** !