

# MAŠINSKO UČENJE

**JELENA JOVANOVIĆ**

Email: jeljov@gmail.com

Web: <http://jelenajovanovic.net>

# PREGLED PREDAVANJA

- Šta je mašinsko učenje?
- Zašto (je potrebno/bitno) m. učenje?
- Oblasti primene m. učenja
- Oblici m. učenja
- Osnovni koraci i elementi procesa m. učenja
  - Podaci
  - Atributi (features)
  - Odabir modela/algoritama m. učenja
  - Validacija i testiranje modela/algoritama

# ŠTA JE MAŠINSKO UČENJE ?

Mašinsko učenje se odnosi na sposobnost softverskog sistema da:

- generalizuje na osnovu prethodnog *iskustva* (podataka), i
- da koristi ove generalizacije kako bi pružio odgovore na pitanja koja se odnose na podatke koje pre nije sretao

# ŠTA JE MAŠINSKO UČENJE ?

Za kompjuterski program se kaže da uči  
iz iskustva  $E$  (*experience*),  
vezanog za zadatak  $T$  (*task*), i  
meru performansi  $P$  (*performance*),  
ukoliko se njegove performanse na zadatku  $T$ , merene  
metrikama  $P$ , unapređuju sa iskustvom  $E$

Tom Mitchell (1997)

# ŠTA JE MAŠINSKO UČENJE ?

Primer: program koji označava poruke kao spam i not-spam

- Zadatak (**T**): klasifikacija email poruka na spam i not-spam
- Iskustvo (**E**): email poruke označene kao spam i not-spam; “posmatranje” korisnika dok označava email poruke
- Performanse (**P**): procenat email poruka korektno klasifikovanih kao spam/not-spam

# ZAŠTO MAŠINSKO UČENJE ?

1) Neke vrste zadataka ljudi rešavaju vrlo lako, a pri tome nisu u mogućnosti da precizno (algoritamski) opišu kako to rade

Primeri: prepoznavanje slika, zvuka, govora

2) Za neke vrste zadataka mogu se definisati algoritmi za rešavanje, ali su ti algoritmi vrlo složeni i/ili zahtevaju velike baze znanja

Primeri: automatsko prevodenje

# ZAŠTO MAŠINSKO UČENJE ?

3) U mnogim oblastima se kontinuirano prikupljaju podaci sa ciljem da se iz njih “nešto sazna”; npr.:

- u medicini: podaci o pacijentima i korišćenim terapijama
- u sportu: o odigranim utakmicama i igri pojedinih igrača
- u marketingu: o korisnicima/kupcima i tome šta su kupili, za šta su se interesovali, kako su proizvode ocenili,...

Analiza podataka ovog tipa zahteva pristupe koji će omogućiti da se otkriju pravilnosti, zakonitosti u podacima koje nisu ni poznate, ni očigledne

# GDE SE PRIMENJUJE MAŠINSKO UČENJE ?

## Brojne oblasti primene

- Kategorizacija teksta prema temi, iskazanim osećanjima i/ili stavovima i sl.
- Mašinsko prevodenje teksta
- Razumevanje govornog jezika
- Prepoznavanje lica na slikama
- Segmentacija tržišta
- Uočavanje paterna u korišćenju različitih aplikacija
- Autonomna vozila (self-driving cars)
- ...

# OBLICI MAŠINSKOG UČENJA

Osnovni oblici mašinskog učenja:

- Nadgledano učenje (supervised learning)
- Nenadgledano učenje (unsupervised learning)
- Učenje uz podsticaje (reinforced learning)

# NADGLEDANO UČENJE

Obuhvata skup problema i tehnika za njihovo rešavanje u kojima algoritam za učenje dobija:

- skup ulaznih podataka ( $x_1, x_2, \dots, x_n$ ) i
- skup željenih/tačnih vrednosti, tako da za svaki ulazni podatak  $x_i$ , imamo željeni/tačan izlaz  $y_i$

Zadatak mašine je da “nauči” kako da novom, neobeleženom ulaznom podatku dodeli tačnu izlaznu vrednost


Izlazna vrednost može biti:

- labela (tj. nominalna vrednost) – reč je o *klasifikaciji*
- realan broj – reč je o *regresiji*

# NADGLEDANO UČENJE

Primer linearne regresije: predikcija cena nekretnina na osnovu njihove površine

Podaci za učenje: površine (x) i cene (y) nekretnina u nekom gradu




# NADGLEDANO UČENJE

Primer linearne regresije (nastavak)

Funkcija koju treba „naučiti“ u ovom slučaju (samo jedan atribut) je:

$$h(x) = a + bx$$

*a* i *b* su koeficijenti koje algoritam u procesu „učenja“ treba da *proceni* na osnovu datih podataka



# NENADGLEDANO UČENJE


Kod nenadgledanog učenja

- nemamo informacija o željenoj izlaznoj vrednosti
- algoritam dobija samo skup ulaznih podataka ( $x_1, x_2, \dots, x_n$ )

Zadatak algoritma je da otkrije paterne tj. skrivene strukture/zakonitosti u podacima

# NENADGLEDANO UČENJE

Primer: određivanje konfekcijskih veličina na osnovu visine i težine ljudi



# UČENJE UZ PODSTICAJE

Ovaj oblik učenja podrazumeva da program (agent) deluje na okruženje izvršavanjem niza akcija

Ove akcije utiču na stanje okruženja, koje povratno utiče na agenta pružajući mu povratne informacije koje mogu biti "nagrade" ili "kazne"

Cilj agenta je da nauči kako da deluje u datom okruženju tako da vremenom max. nagrade (ili min. kazne)

Primer: autonomna vozila

# **OSNOVNI KORACI I ELEMENTI PROCESA M. UČENJA**

# OSNOVNI KORACI PROCESA M. UČENJA

- 1) *Prikupljanje podataka potrebnih za formiranje dataset-ova za obuku, validaciju i testiranje algoritama m. učenja*
- 2) Priprema podataka, što tipično podrazumeva “čišćenje” i transformaciju podataka
- 3) Analiza rezultujućih dataset-ova, i njihovo, eventualno, dalje unapređenje kroz selekciju/transformaciju atributa
- 4) Izbor 1 ili više algoritama za obuku nad kreiranim trening dataset-om
- 5) Evaluacija izabranih algoritama na dataset-u za validaciju
- 6) Izbor algoritma koji će se koristiti (na osnovu rezultata koraka 5) i njegovo testiranje na test dataset-u

# PODACI

Podaci su potrebni za trening, validaciju i testiranje algoritama

- Tipična podjela podataka kojima raspolažemo je 60% za trening, 20% za validaciju i 20% za testiranje
- Izbor uzorka za trening, validaciju i testiranje treba da se uradi na slučajan način (random selection)

Za nadgledano učenje, moramo imati “obeležene” podatke

- Npr. obeležiti slike koje sadrže lice, elektronsku poštu koja je nepoželjna, e-mail adrese koje su lažne, i sl.

# PODACI

## Izvori podataka:

- Javno dostupne kolekcije podataka; sve više tzv. otvorenih podataka (open data)
  - Pogledati npr. <http://bitly.com/bundles/bigmlcom/4>
- Podaci dostupni posredstvom Web API-a
  - Pogledati npr. <http://www.programmableweb.com/>
- Sve veće tržište gde je moguće kupiti podatke
  - Pogledati npr. <http://datamarket.com/>

# PODACI

**Preporuka:** predavanje Peter Norvig-a na temu značaja podataka za mašinsko učenje:

The Unreasonable Effectiveness of Data

URL: <http://www.youtube.com/watch?v=yvDCzhabjYWs>

# ATRIBUTI (FEATURES)

Osnovna ideja:

- pojave/entitete prepoznajemo uočavajući njihove osobine (ili izostanak nekih osobina) i uviđajući odnose između različitih osobina
- omogućiti programu da koristi osobine pojave/entiteta za potrebe njihove identifikacije/grupisanja

Izazov:

- odabrati attribute koji najbolje opisuju neki entitet/pojavu, tj. omogućuju distinkciju entiteta/pojava različitog tipa

# ATRIBUTI (FEATURES)

Primeri:

- Za elektronsku poštu: naslov (tj. polje subject), reči napisane velikim slovom, dužina email-a, prva reč i sl.
- Za stan: površina, lokacija, broj soba, tip grejanja i sl.
- Za tweet poruke: prisustvo linkova, prisustvo hashtag-ova, vreme slanja, pošiljalac, ...





# ODABIR ALGORITMA

Generalno, zavisi od:

- vrste problema koji rešavamo,
- karakteristika skupa atributa (features)
  - tip atributa i stepen homogenosti tipova atributa
  - stepen međuzavisnosti (korelisanosti) atributa
- obima podataka koji su nam na raspolaganju

# ODABIR ALGORITMA

Primer: pokušaj aproksimacije četiri različita skupa podataka primenom iste linearne funkcije (tj. linearne regresije)



# TESTIRANJE

Za procenu uspešnosti algoritma, potrebni su podaci koje algoritam nije imao prilike da “vidi” u fazi učenja

Reč je o podacima za testiranje, za koje se obično izdvaja 20-30% ukupnih podataka

Uspešnost algoritma se utvrđuje različitim metrikama:  
tačnost, preciznost, odziv, ...

# TRAIN/VALIDATE/TEST

Pored treniranja i testiranja algoritma, najčešće se radi i validacija algoritma kako bi se:

- a) izabrao najbolji model/algoritam između više kandidata
- b) odredila optimalna konfiguracija parametara modela
- c) izbegli problemi *over/under-fitting-a*

U ovim slučajevima, ukupan dataset deli se u odnosu 60/20/20 na podatke za trening, validaciju i testiranje

Podaci za validaciju koriste se za poređenje performansi

- različitih algoritama (a);
- izabranog algoritma sa različitim vrednostima parametara (b)


# CROSS-VALIDATION

Čest pristup za efikasno korišćenje raspoloživih podataka

Kako funkcioniše:

- raspoloživi skup podataka za trening se podeli na K delova ili podskupova (*folds*)
  - najčešće se uzima 10 podskupova (*10 fold cross validation*)
- zatim se obavlja K iteracija (trening + validacija) algoritma; u svakoj iteraciji:
  - uzima se 1 deo podataka za potrebe validacije, a ostatak ( $K-1$  deo) se koristi za učenje
  - bira se uvek različiti podskup koji će se koristiti za validaciju

# CROSS VALIDATION



# CROSS VALIDATION

Pri svakoj iteraciji računaju se performanse algoritma

Na kraju se računa prosečna uspešnost na nivou svih K iteracija – tako izračunate mere uspešnosti daju bolju sliku o performansama algoritma

Ukoliko su rezultati u svih K iteracija vrlo slični, smatra se da je procena uspešnosti algoritma pouzdana

# ANALIZA GREŠKE


Podrazumeva “ručno” pregledanje primera na kojima je algoritam pravio greške i uočavanje paterna u tim primerima

Pomaže da se stekne osećaj zbog čega algoritam greši, i šta bi se moglo uraditi da se greške otklone; Npr.


- identifikovati suvišne atrIBUTE
- identifikovati atrIBUTE koji nedostaju
- drugačije podesiti parametre algoritma
- ...

# PROBLEM PREVELIKOG PODUDARANJA (OVER-FITTING)

Odnosi na situaciju u kojoj algoritam savršeno nauči da prepoznae instance iz trening seta, ali nije u mogućnosti da prepozna instance koje se i malo razlikuju od naučenih




**poželjno rešenje**




**over fitting**

# PROBLEM NEDOVOLJNOG PODUDARANJA (UNDER-FITTING)

*Under-fitting* se odnosi na slučaj kad algoritam ne uspeva da aproksimira podatke za trening, tako da ima slabe performanse čak i na trening setu



# OVER-FITTING VS. UNDER-FITTING



# ZAHVALNICE I PREPORUKE

# Stanford

## Machine Learning

Andrew Ng


Learn about the most effective machine learning techniques, and gain practice implementing them and getting them to work for yourself.

**Workload:** 5-7 hours/week

**Taught In:** English

**Subtitles Available In:** English

Preview



### Sessions:

Oct 14th 2013 (10 weeks long)

[Sign Up](#)

Apr 22nd 2013 (10 weeks long)

[Sign Up](#)

3,484

12k

13k

[Tweet](#)

[+1](#)


[Like](#)

Coursera:


<https://www.coursera.org/course/ml>

Stanford YouTube channel:

[http://www.youtube.com/view\\_play\\_list?p=A89DCFA6ADACE599](http://www.youtube.com/view_play_list?p=A89DCFA6ADACE599)



<http://www.cs.waikato.ac.nz/ml/weka/book.html>



## Machine learning - introduction

Nando de Freitas · 81 videos  
Subscribe 1,514

3,357

16 0

A screenshot of a YouTube channel page for "Nando de Freitas". It shows 81 videos, 1,514 subscribers, and 3,357 views. The video player shows a timestamp of 03:53 / 59:59.

Machine Learning: The Basics, with Ron Bekkerman by LinkedInTechTalks 16,919 views

Andrew Ng: Deep Learning, Self-Taught Learning and Unsupervised Feature

A screenshot of a YouTube search results page for "Machine Learning". The top result is "Machine Learning: The Basics, with Ron Bekkerman" by LinkedInTechTalks, with 16,919 views. Below it is a result by Andrew Ng titled "Deep Learning, Self-Taught Learning and Unsupervised Feature".

# Predavanja Nando de Freitas-a na UBC-u

<http://www.youtube.com/watch?v=w2OtwL5T1ow>

(Anonimni) upitnik za vaše kritike,  
komentare, predloge:

<http://goo.gl/cqdp3I>