

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
- Bias (under-fitting) vs. Variance (over-fitting)

ŠTA JE MAŠINSKO UČENJE ?

Mašinsko učenje se odnosi na sposobnost softverskog sistema da:

- *generalizuje* na osnovu prethodnog *iskustva*,
 - *iskustvo* = skup podataka o pojavama/entitetima koji su predmet učenja
- da koristi kreirane generalizacije kako bi pružio odgovore na pitanja koja se tiču entiteta/pojava 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***): skup email poruka označenih 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 prevođenje

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, a mogu biti korisne

GDE SE PRIMENJUJE MAŠINSKO UČENJE ?

Brojne oblasti primene

- Kategorizacija teksta prema temi, iskazanim osećanjima i/ili stavovima i sl.
- Mašinsko prevođenje teksta
- Razumevanje govornog jezika
- Prepoznavanje lica na slikama
- Segmentacija tržišta
- Uočavanje paternu 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 program koji uči 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 programa 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



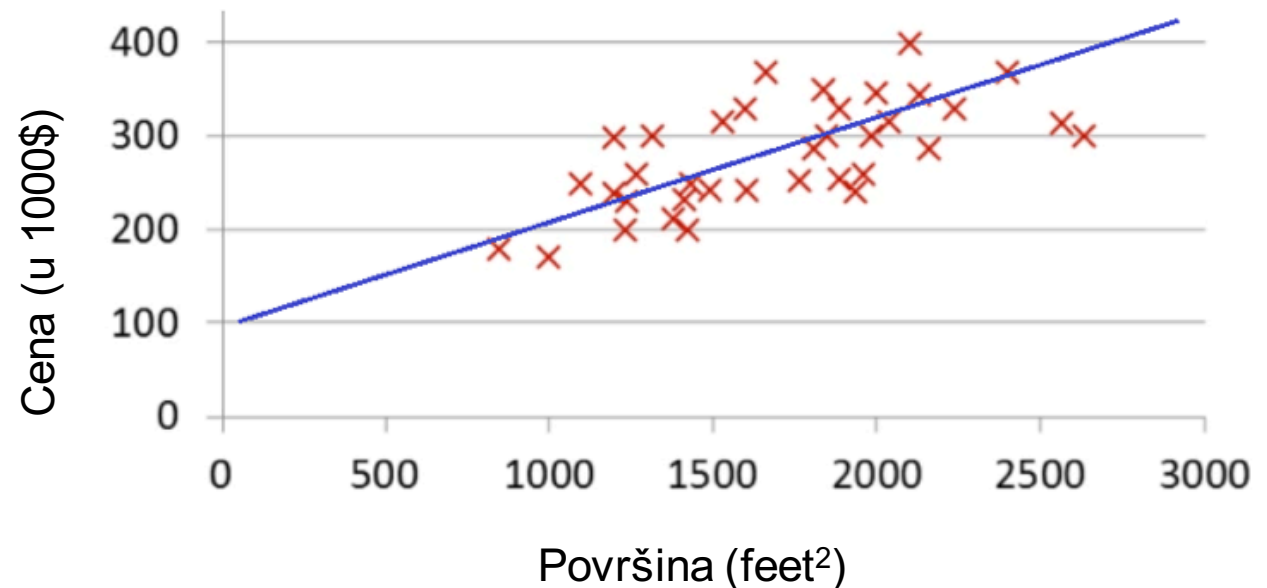
NADGLEDANO UČENJE

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 program u procesu „učenja“ treba da *proceni* na osnovu datih podataka



NENADGLEDANO UČENJE



Kod nenadgledanog učenja

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

Zadatak programa je da otkrije paterne tj. skrivene strukture/zakovitosti u podacima

NENADGLEDANO UČENJE

Primer: određivanje konfekcijskih veličina na osnovu visine i težine ljudi



UČENJE UZ PODSTICAJE

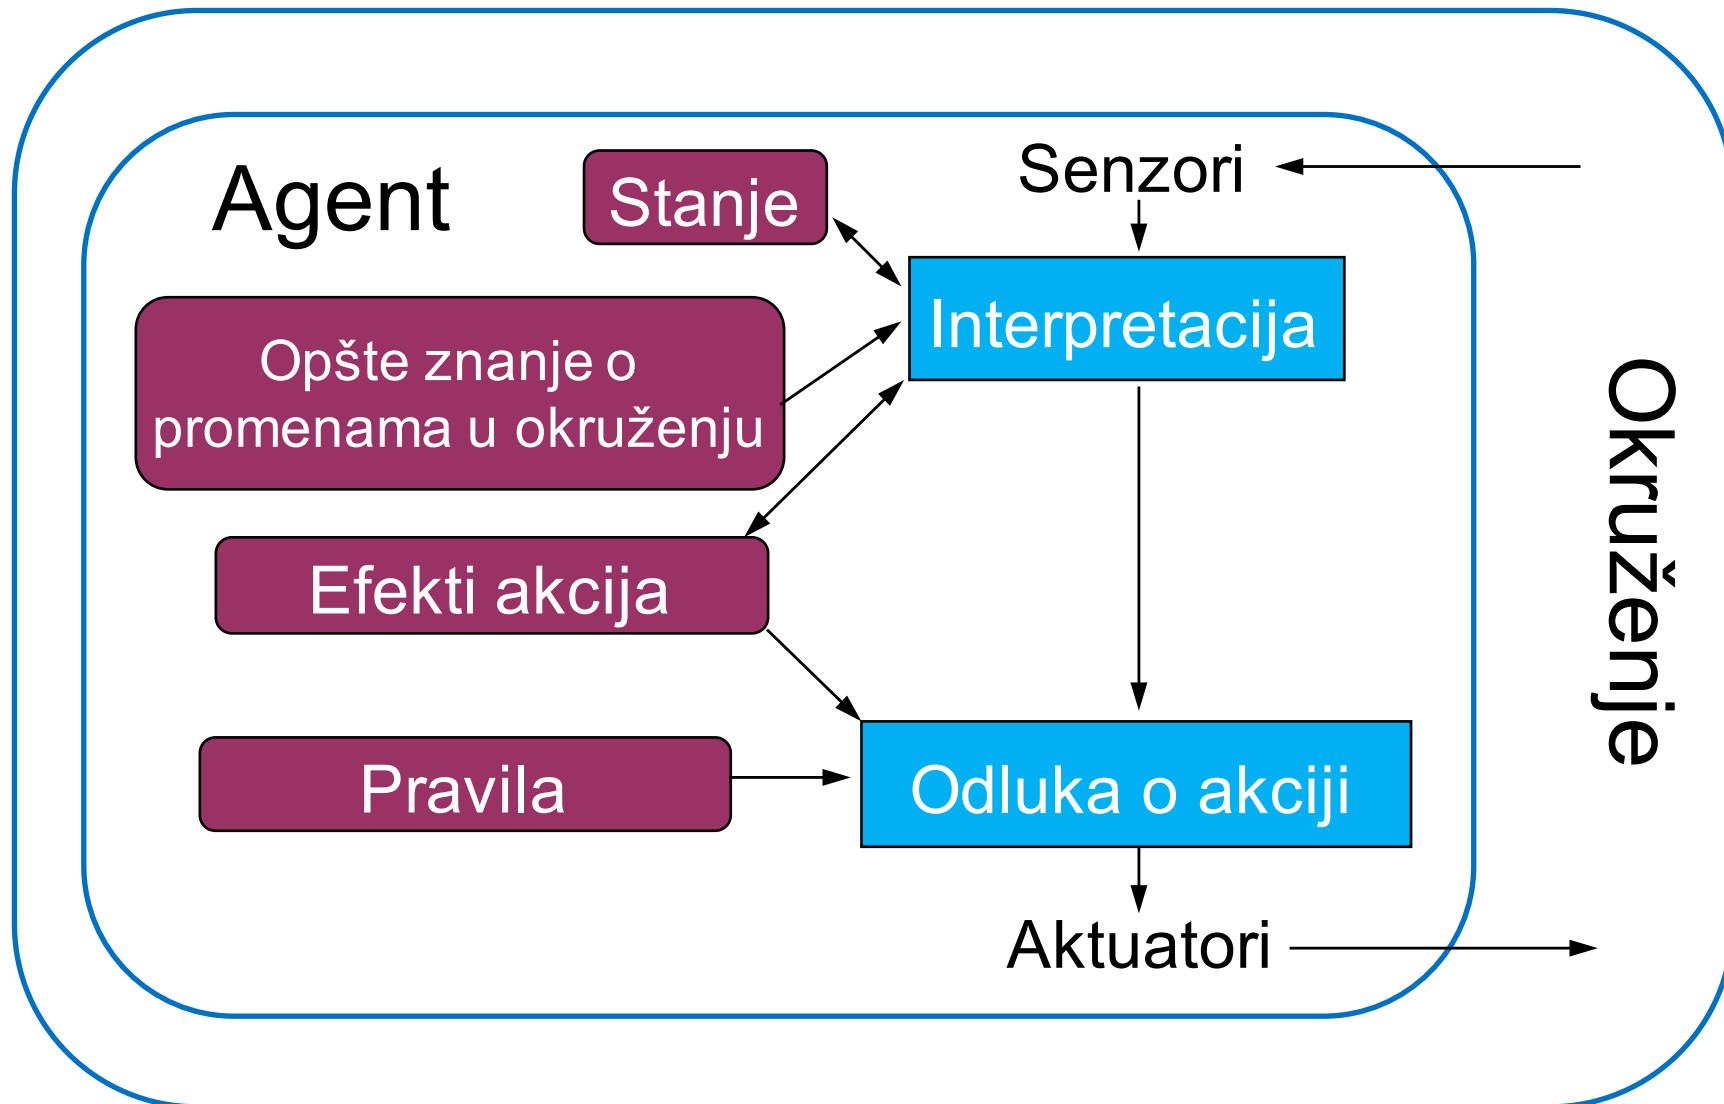
Ovaj oblik učenja podrazumeva da program (agent) deluje na okruženje izvršavanjem niza akcija

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: kompjuterske igre, autonomna vozila

ILUSTRACIJA AGENTA KOJI UČI UZ PODSTICAJE



OSNOVNI
KORACI I ELEMENTI
PROCESA M. UČENJA



OSNOVNI KORACI PROCESA M. UČENJA

- 1) *Prikupljanje podataka* potrebnih za formiranje datasets za obuku, (validaciju) i testiranje modela m. učenja
- 2) Priprema podataka, što tipično podrazumeva “čišćenje” i *transformaciju podataka*
- 3) Analiza rezultujućih datasets, i njihovo, eventualno, dalje unapređenje kroz *selekciju/transformaciju atributa*
- 4) *Izbor 1 ili više metoda* m. učenja
- 5) *Obuka, konfiguracija i evaluacija kreiranih modela*
- 6) Izbor modela koji će se koristiti (na osnovu rezultata koraka 5) i njegovo *testiranje*

PODACI

Podaci su potrebni za trening, validaciju i testiranje modela

- Tipična podjela podataka kojima raspolažemo je 60% za trening, 20% za validaciju i 20% za testiranje
- Izbor uzoraka 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. <https://github.com/caesar0301/awesome-public-datasets>
- Podaci dostupni posredstvom Web API-a
 - Pogledati npr. <http://www.programmableweb.com/>
- Sve veće tržište gde je moguće kupiti podatke
 - Pogledati npr. <http://www.qlik.com/us/products/qlik-data-market>

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=yvDCzhbjYWs>

*Peter Norvig je autor jedne od najpoznatijih knjiga u domenu Veštačke inteligencije i trenutno na poziciji Director of Research u Google-u

ATRIBUTI (FEATURES)

Osnovna ideja:

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

Izazov:

- odabrati atribute 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 hashtagova, vreme slanja, mrežna pozicija pošiljaoca, ...





ODABIR METODE M. UČENJA

Generalno, zavisi od:

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

ODABIR METODE M. UČENJA

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



Očigledno različiti podaci traže različite funkcije tj algoritme učenja

TESTIRANJE

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

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

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

TRAIN/VALIDATE/TEST

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

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

(ovi problemi su objašnjeni na slajdovima 33-41)

TRAIN/VALIDATE/TEST

Kad se radi validacija, ukupan dataset se obično deli u odnosu 60/20/20 na podatke za trening, validaciju i testiranje

Podaci za validaciju koriste se za poređenje performansi

- različitih modela
 - izabranog modela sa različitim vrednostima parametara
- sve u cilju izbora optimalnog modela za dati problem

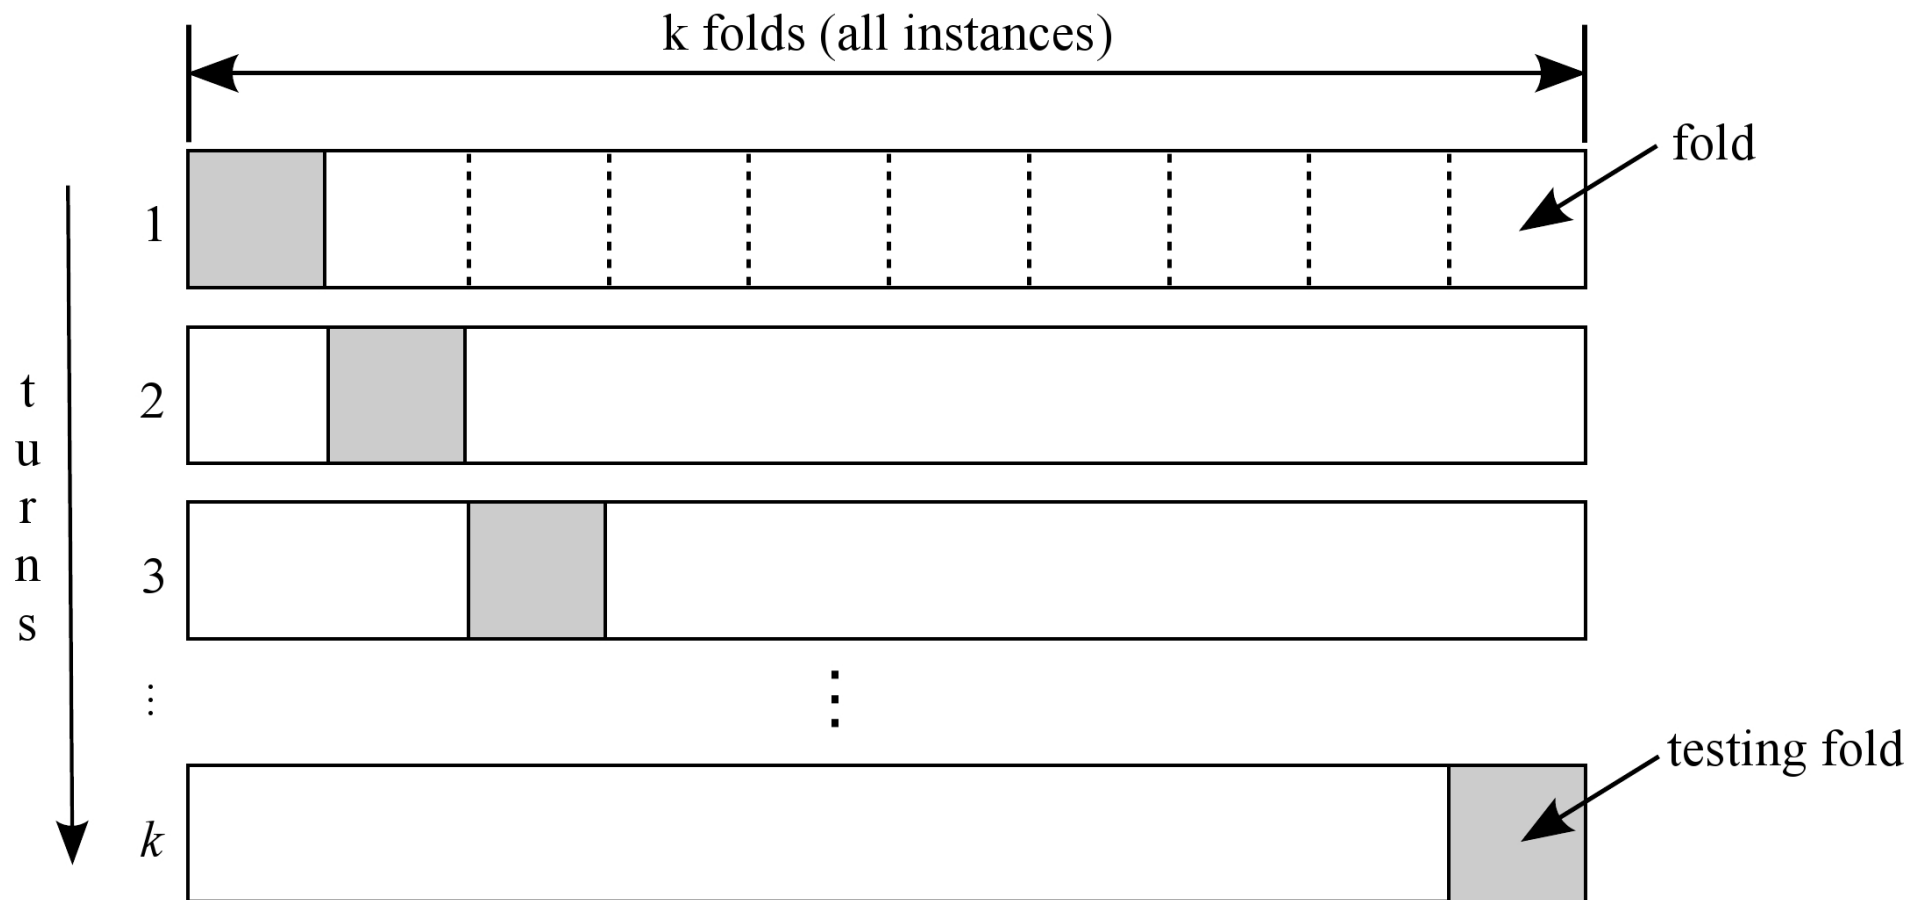
CROSS-VALIDATION

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 treninga + validacije modela ; u svakoj iteraciji:
 - uzima se 1 deo (*fold*) 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 modela

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

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

ANALIZA GREŠKE

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

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

- identifikovati suvišne attribute
- identifikovati attribute koji nedostaju
- drugačije podesiti parametre modela
- ...

OVER-FITTING (VARIANCE)

VS.

UNDER-FITTING (BIAS)




BIAS / VARIANCE TRADE-OFF


Bias (under-fitting) i *variance (over-fitting)* su dve bitne pojave koje je potrebno razmotriti pri kreiranju modela mašinskog učenja

PROBLEM PREVELIKOG PODUDARANJA (OVER-FITTING)

Odnosi na situaciju u kojoj model savršeno nauči da vrši predikciju za instance iz trening seta, ali ima veoma slabu sposobnost predikcije za instance koje se i malo razlikuju od naučenih



over fitting




poželjno rešenje

PROBLEM PREVELIKOG PODUDARANJA (OVER-FITTING)


Problem over-fitting-a je usko povezan sa visokom varijansom (*variance*) korišćene metode m. učenja

VARIJANSA METODA M. UČENJA

- Varijansa (*variance*) ukazuje na to u kojoj meri bi se kreirani model m. učenja promenio ukoliko bi došlo do promene podataka u korišćenom skupu za trening
- Generalno, što je metoda m. učenja složenija / fleksibilnija, to će njena varijansa biti veća




visoka varijansa




mala varijansa

PROBLEM NEDOVOLJNOG PODUDARANJA (UNDER-FITTING)

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



under fitting



poželjno rešenje

PROBLEM NEDOVOLJNOG PODUDARANJA (UNDER-FITTING)

Under-fitting problem je usko povezan sa visokim *bias-om* korišćene metode m. učenja


BIAS METODA M. UČENJA

- **Bias** se odnosi na grešku koja se javlja u slučaju korišćenja vrlo jednostavnog modela za potrebe rešavanja složenog realnog problema
- Na primer, linearna regresija podrazumeva postojanje lin. relacije između zavisne i nezavisne varijable; međutim, u realnosti, relacije su vrlo retko linearne; usled toga, modele zasnovane na lin. reg. često karakteriše visok *bias*
- Generalno, što je metoda m. učenja složenija / fleksibilnija, to će *bias* biti manji

BIAS / VARIANCE: PRIMER

Bias/variance regresionog modela za predviđanje cene kuće (zavisna promenljiva) na osnovu njene veličine (prediktor)


d je stepen polinoma primenjene regresione metode




Izvor:

http://www.astroml.org/sklearn_tutorial/practical.html

OVER-FITTING VS. UNDER-FITTING



BIAS - VARIANCE DILEMMA / TRADE-OFF



Bias Variance Decomposition. Figure 1. The bias-variance decomposition is like trying to hit the bullseye on a dartboard. Each dart is thrown after training our “dart-throwing” model in a slightly different manner. If the darts vary wildly, the learner is *high variance*. If they are far from the bullseye, the learner is *high bias*. The ideal is clearly to have both low bias and low variance; however this is often difficult, giving an alternative terminology as the bias-variance “dilemma” (*Dartboard analogy*, Moore & McCabe (2002))

ZAHVALNICE I PREPORUKE




Home > Data Science > Machine Learning

Machine Learning


About this course: Machine learning is the science of getting computers to act without being explicitly programmed. In the past decade, machine learning has given us self-driving cars, practical speech recognition, effective web search, and a vastly improved understanding of the human genome. Machine learning is so pervasive today that you probably use it dozens of times a day without knowing it. Many

[▼ More](#)

Created by: Stanford University



Taught by: Andrew Ng, Associate Professor, Stanford University; Chief Scientist, Baidu; Chairman and Co-founder, Coursera



Financial Aid is available for learners who cannot afford the fee. [Learn more and apply.](#)

Overview

Syllabus

Creators

Ratings and Reviews

Machine Learning


Enroll Now
Starts Oct 03

Coursera:

<https://www.coursera.org/learn/machine-learning>

Stanford YouTube channel:

http://www.youtube.com/view_play_list?p=A89DCFA6ADACE599



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

Springer Texts in Statistics

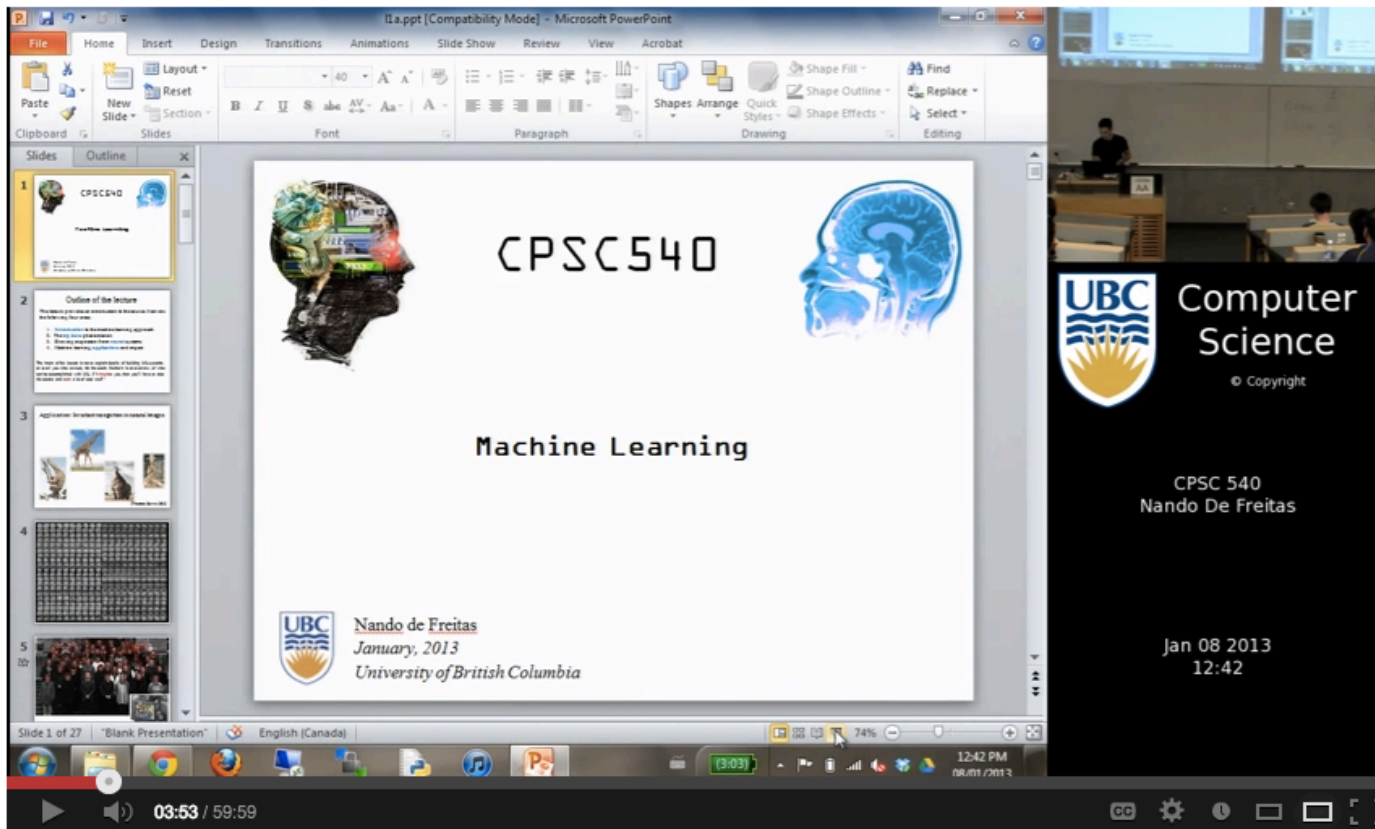
Gareth James
Daniela Witten
Trevor Hastie
Robert Tibshirani

An Introduction to Statistical Learning

with Applications in R

 Springer

<http://www-bcf.usc.edu/~gareth/ISL/index.html>



Machine learning - introduction




Nando de Freitas · 81 videos

 1,514


3,357

 16  0



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



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

Predavanja Nando de Freitas-a na UBC-u

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

PREPORUČENI TEKSTOVI

- [blog post] Designing ML models ([link](#))
 - jednostavan i lep primer postupka kreiranja i evaluacije ML modela
- [blog post] Preparing data for analysis ([link](#))
 - sažeto objašnjeno zašto je (jako) bitno da se adekvatno uradi priprema podataka (“čišćenje” i transformacija)
- [article] A Tour of Machine Learning Algorithms ([link](#))
 - lep i sažet pregled velikog broja popularnih ML algoritama
- [post] Machine Learning Algorithm Cheat Sheet ([link](#))
 - pros & cons nekoliko popularnih algoritama (DT, Lin. Regression, NN, SVM, kNN); vrlo praktično i korisno
- [article] Essentials of Machine Learning Algorithms (with Python and R Codes) ([link](#))

NEKI (POTENCIJALNO) INTERESANTNI PRIMERI PRIMENE MAŠINSKOG UČENJA

- NELL - Never Ending Language Learner ([website](#)) ([NYT article](#)) ([video lecture](#))
- [Relationship mining on Twitter](#)
- [What Facebook Knows](#) (data analysis at Facebook)
- [Using Location Data to Predict the Events You Will Want to Attend](#)
- [Smart Autofill - Harnessing the Predictive Power of Machine Learning in Google Sheets](#)
- [Deep Learning](#) (what it is about)
- Learning Analytics and MOOCs ([TED talk](#)) ([research paper](#) on the use of ML to predict dropouts in MOOCs)

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

<http://goo.gl/cqdp3l>