

Univerza v Ljubljani
Fakulteta *za računalništvo
in informatiko*



31. 5. 2018

Globoko učenje za analizo slik in besedil

prof. dr. Marko Robnik-Šikonja



Vsebina

- delovanje globokih nevronske mreže
- analiza slik
- analiza besedil



Umetna inteligenca v medijih

Nas bodo roboti uničili?

Nam bo umetna inteligenca vzela službe?

Bomo še potrebovali vozniško?

Bomo še potrebovali zdravnike?

Kako se bodo razvijali humanoidi roboti?

Kaj bo s kiborgi?

Kaj je splošna umetna inteligenca?

Kaj je tehnološka singularnost?



Zgodovina, učiteljica življenja?

- kratka zgodovina optimizma na področju umetne inteligence
- začetek v 1950. letih, 1956 Dartmouth konferenca
- velika pričakovanja, veliko podcenjevanja težavnosti problemov
- AI winter (2 x)

1958, H. A. Simon and Allen Newell: "... within ten years a digital computer will discover and prove an important new mathematical theorem."

1965, H. A. Simon: "... machines will be capable, within twenty years, of doing any work a man can do."

1967, Marvin Minsky: "Within a generation ... the problem of creating 'artificial intelligence' will substantially be solved."

1970, Marvin Minsky: "In from three to eight years we will have a machine with the general intelligence of an average human being."





Umetna inteligenca

- interdisciplinarno raziskovalno področje: računalništvo, nevrologija, matematika, psihologija, itd.
- splošne metode, uporabne na številnih področjih
- strojno učenje, inteligentna analiza podatkov, podatkovno rudarjenje, podatkovna znanost
- razumevanje naravnega jezika
- računalniški vid
- robotika
- evolucijsko računanje in optimizacija
- spodbujevano učenje - kontrola, vodenje
- načrtovanje, sklepanje
- preiskovanje
- večagentni sistemi
- aplikacije: npr. medicina, farmacija, finance, industrija, šport, telekomunikacije, zavarovalništvo, genetika, marketing, sociologija, jezik itn.



Umetne nevrnske mreže: analogija z možgani




učenje: vzratno razširjanje napake



Globoko učenje =

globoke nevronske mreže + velike učne množice + GPU
(+konvolucija ali +rekurenčnost)



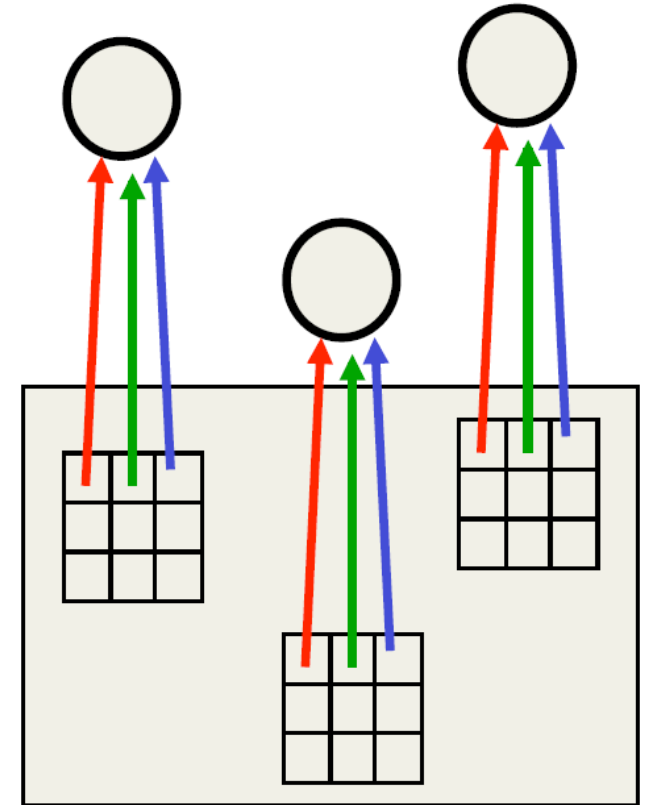


Zakaj delujejo?



Konvolucijske nevronske mreže

- convolutional neural networks, CNN
- trenutno najuspešnejši pristop pri razpoznavanju slik, zelo uspešen v naravnem jeziku
- ideja: mnogo kopij istega majhnega prepoznavalnika, ki ga uporabimo na različnih mestih, rezultate globoka mreža kombinira v pomembnejše značilke



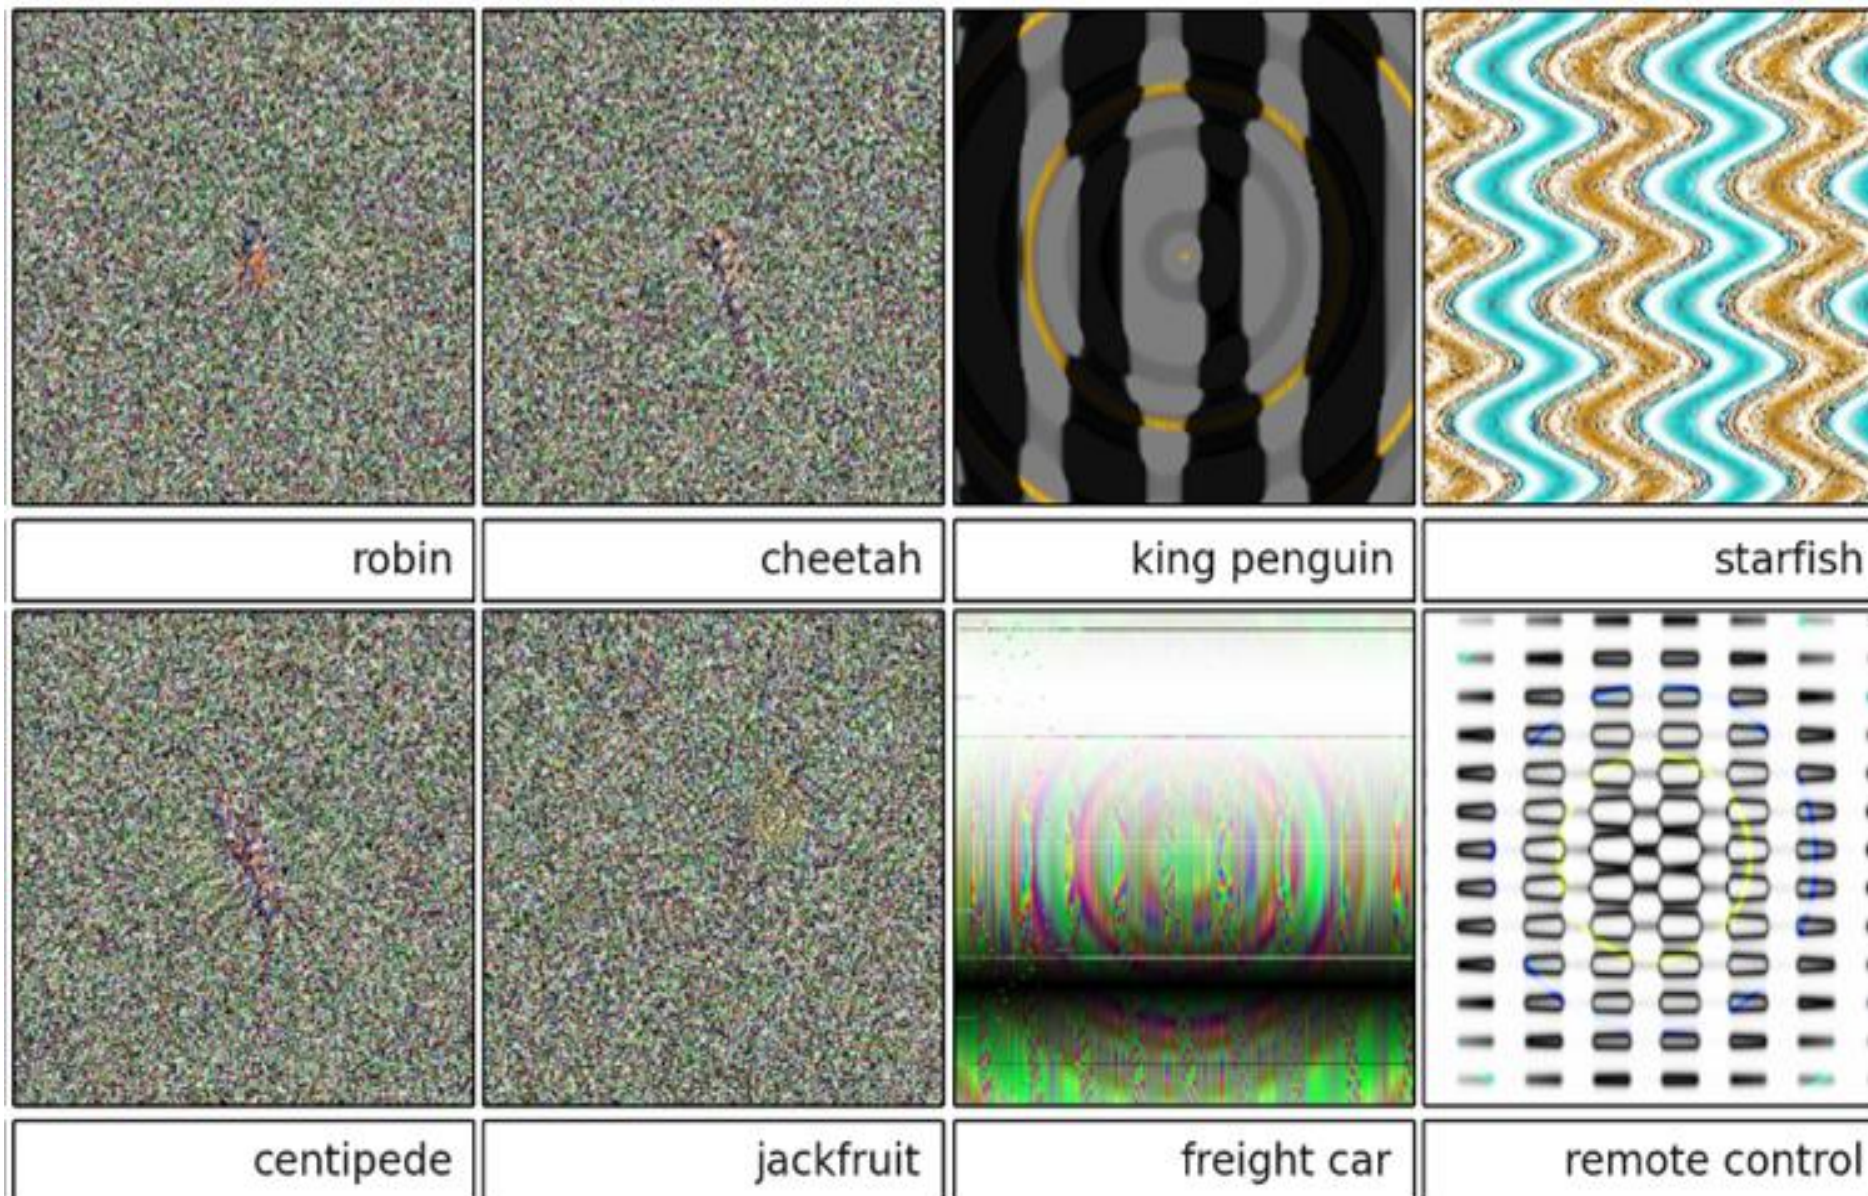
povezave iste barve imajo enake uteži

prilagodimo postopek vzratnega razširjanja napake

Uspehi globokega učenja





Pomanjkljivosti globokega učenja





place sticker on table



Napadi na nevrnske mreže



Analiza slik

- Wang, Y., & Kosinski, M. (in press). Deep neural networks are more accurate than humans at detecting sexual orientation from facial images. *Journal of Personality and Social Psychology*.
- demonstracija zmožnosti globokega učenja, odpiranje metodoloških in etičnih vprašanj
- avtorja odgovarjata na nekatere kritike in etične dileme v posebnem dokumentu



Ozadje

- Fiziognomija (physiognomy) trdi, da obstajajo povezave med našim značajem in videzom – pri tem se najbolj osredotoča na obliko in poteze obraza, pa tudi na roke in druge dele telesa. Začetki: antika, npr. Aristotel in Pitagora.
- zavrnjena in tabuizirana v 20. stoletju, vendar
- obstajajo nekatere raziskave, ki kažejo, da ljudje z majhno, vendar značilno višjo verjetnostjo od naključne prepoznavamo nekatere lastnosti: spol, starost, rasa, čustvena stanja, osebnostne lastnosti, spolna usmerjenost, politično prepričanje, možnost zmage na volitvah
- vpliv na obraz imajo npr.: pred in poporodna izpostavljenost hormonom, okoljski in genetski vplivi itd.
- predporodna hormonska teorija (prenatal hormone therapy): istospolno orientiranost povzroča premajhna izpostavljenost moškega ali prev elika izpostavljenost ženskega fetusa moškimi spolnimi hormonom; isti hormoni povzročijo tudi spolno diferenciacijo obraza
- hipoteza: istospolni moški imajo manjše čeljusti in lica, tanjše obrvi, daljši nos in večje čelo (obratno za ženske); spolno atipično bo tudi oblačenje, frizura, nega obraza itd.
- namen: preveriti hipotezo, ozavestiti istospolno skupnost o tehnoloških zmožnosti odkrivanja spolne usmerjenosti



Podatki in priprava značilk

- Vir: slike s spletnega mesta za zmenke, spol in spol iskanega partnerja določata spolno usmerjenost
- Začetek: 130.741 slik 36.630 moških, 170.360 slik 38.593 žensk, starost med 18 in 40, enako število homo in heteroseksualnih,
- Čiščenje (Face++, AMT) za izločitev premajhnih, nagnjenih, nestandardnih, nekavkazijskih slik ostane 35.326 slik, približno 50:50% moški:ženske, isto:različno spolno usmerjeni, velikost 224 x 24 točk, od 1-5 slik za posameznika
- globoke nevronske mreže za ekstrakcijo značilk, VGG-Face naučena na 2.6 milijona slik za prepoznavanje obrazov: 4096 značilk
- redukcija množice značilk s postopkom SVD: rezultat 500 značilk
- klasifikator: logistična regresija, LASSO regularizacija, 20-kratno prečno preverjanje
- članek kot klasifikacijsko točnost poroča AUC (Area Under the ROC curve), 0.81 pomeni, da je med naključno izbranimi pari homo:heteroseksualnih oseb klasifikator zadel v 81% primerov; kot pri Wilcoxonovem testu s predznačenimi rangi



Rezultati

- cilji:
 - ločiti homoseksualne moške od heteroseksualnih; ločiti homoseksualne ženske od heteroseksualnih;
 - kateri deli obraza so pomembni za ločevanje (skrivanje delov)
 - tipičen obraz isto/različno spolno usmerjenih
 - kako dobro prepoznavajo ljudi
- rezultati ločevanja glede na spolno usmerjenost
 - ena slika obraza: moški AUC= 0.81 klasifikacijska točnost, ženske AUC=0.71
 - ljudje (35 sodnikov): moški 0.61, ženske 0.54
 - pet obraznih slik: moški 0.91, ženske 0.83
- pomembni deli obraza: usta, nos, brada
- Poskus razlage je predporodna hormonska teorija: homoseksualni moški in ženske imajo za svoj spol netipično obrazno morfologijo, izraz, stil frizure itd.
- posledice za razumevanje spolne usmerjenosti in omejenost človeške zmožnosti prepoznavanja



Omejitve, pomanjkljivosti in dileme

- metodologija: so slike reprezentativne glede na to, da so uporabniške in s spletišča za zmenke ali odprto homoseksualne (Facebook profili)
- samo belci, odprto istospolno usmerjeni,
- uspešnost ljudi: tipično nimamo na voljo tako označene učne množice
- etične dileme glede zasebnosti spolne usmerjenosti, uporabe s strani vlad in podjetij, digitalnih sledi

- podobne študije glede uspešnosti globokih nevronske mreže obstajajo na številnih področjih, npr. prepoznavanje rakavega tkiva, objektivnega določanja poškodb avtomobilov po toči, razpoznavanja govora v šumnem okolju, itd.



Analiza sentimenta in čustev

- različne delitve čustvovanja
 - pozitivna in negativna čustva v besedilih
 - orodje za analizo družbenih dogajanj preko medijev, spleta, Twitterja
 - nekaj baz podatkov tudi za slovenščino
 - primer: Janes
-
- analiza političnih dogajanj, sovražnega govora, lažnih novic
 - analiza naklonjenosti izdelkom, politikom, idejam,



Osnovni pristop

- priprava podatkov, npr. tвитov
- označevanje s pomočjo ljudi (ujemanje anotatorjev)
- tokenizacija
- ekstrakcija značilk
- uporaba različnih klasifikatorjev
- metodološko pravilna statistična analiza

Mozetič, I., Grčar, M. and Smailović, J., 2016. Multilingual Twitter sentiment classification: The role of human annotators. *PLoS ONE*, 11(5), p.e0155036.

Kadunc, K. Robnik-Šikonja, M. 2016. Analiza mnenj s pomočjo strojnega učenja in slovenskega leksikona sentimenta. V Zbornik JTDH 2016, str. 83-89

Vaš izbor

Vale zaželjene knjige:

Vale nezaželjene knjige:

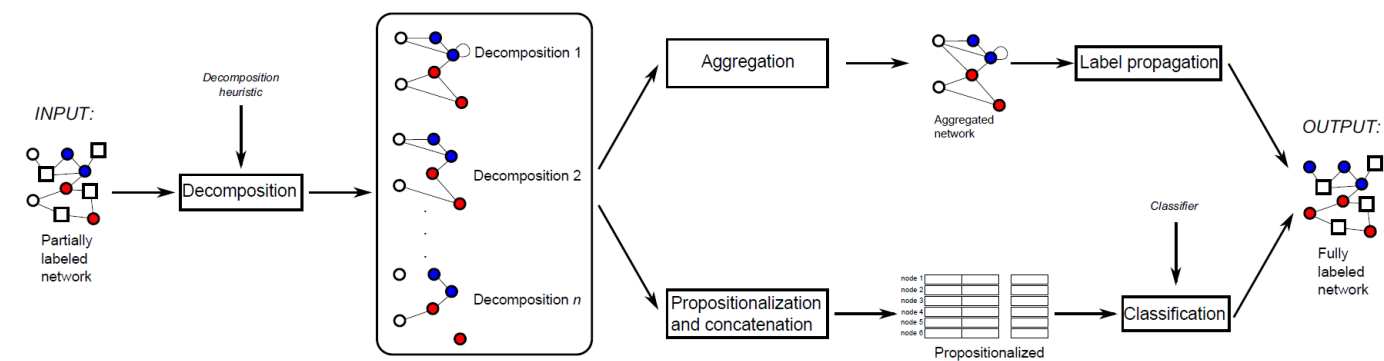
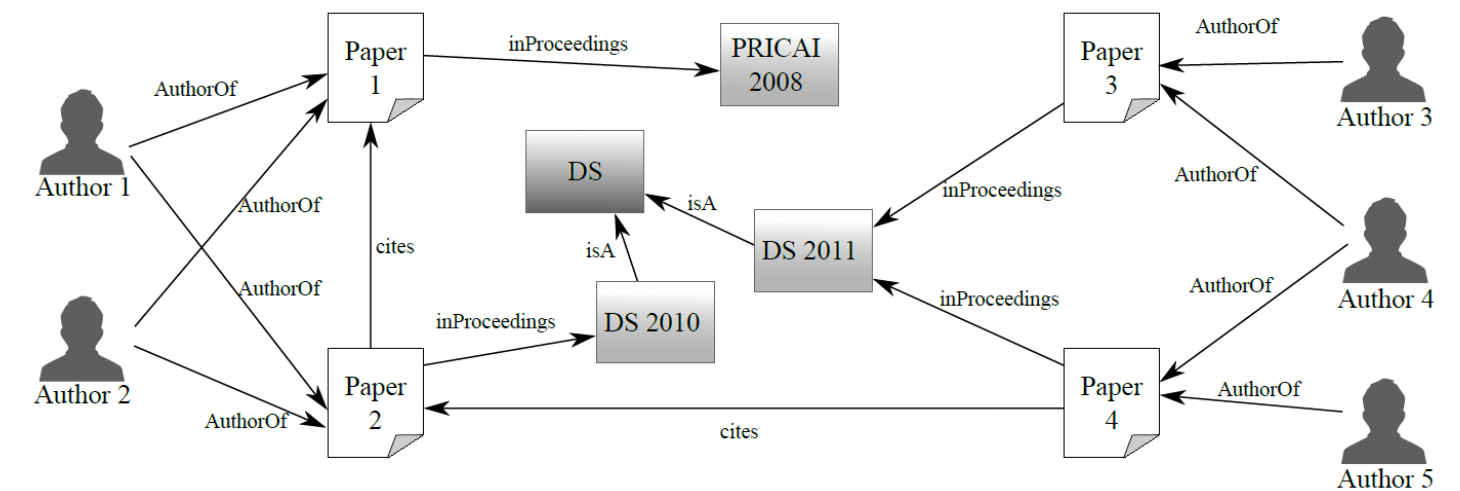
Ocenjevanje seznamov s predlogi

Razvrsti sezname po kvaliteti od prvega do zadnjega mesta. Uporabi ikono za razvrščanje. Ko končaš, klikni na gumb shrani.

Z miliko ptičini na ikono in premakni seznam na novo mesto.

Shrani

1. MESTO	John Perkins: Spornost ekonomskega teorija	Milan Komar: Pot iz mita	Marcel Bežanič: Umetnost, ambicija in moda	Fabrice Hadjadj: Vse domovni ali presežni	Franco Fibero: Ivan Hribovič	Clemen: O dobovost	Jean-Marie Perle: Resebran biografija in spomini	Karmen Berk: Šerški morice	Karel Gržan: La lag padce Big v nabesih, ko je na smrti	Fabrice Hadjadj: Kako vspe v smrti
2. MESTO	Andrej Kovačič: Zbrane pesni / Švedsko Kovačič: Poezija in dramatika	Anton Tomič: Linhart: Ta veseli se žani ali Matičič se žani	Andrej Kovačič: Maelia, Jo Pelebar, Maja Andela	Fabrice Hadjadj: Menesda-Bene	Ivan Cankar: Za narodov blagor	J. Zelen: delovnih namerih (2006-1)	Andrij E. Šubr: Lasko	Zofka Kvedrov: Amerikanci	Ivan Cankar: Romanič Oula	Fran Ožbolt: Dva skopka
3. MESTO	Julij Jurič: Težnja pedona	Ivan Cankar: Zvijevje in smrt	Simon Jenko: Ibrane pesni	Tomaž Saloman: Poezija in logika	Zmaga Štebet: Poezija in logika	Anton Medved: Peami 1	Alex Berger: Knjiga redi	Jozef Jurič: Sin	Zdenko Vidovec: Zgodovna kina	
4. MESTO	Douglas Adams: Nestrastni ob koncu Vesolja	Matjaž Brancar: PRICAI '08	Nevila Amarilo: Libevarski roman	Josip Jurič: Rakovnjači	Vladimir Bajec: Haman Babarja	Catherine Rybee: Soproga vrede	Jonas Jonasson: Švedski, ki je zlezi skoci okno	Bogdan Novak: Zborni med brati	Natasha Soeski: Kamenji aboridžinskega	Dr. Gary Holz: Zgodovna kina



KRALJ, Jan, ROBNIK ŠIKONJA, Marko, LAVRAČ, Nada. HINMINE: heterogeneous information network mining with information retrieval heuristics. *Journal of intelligent information systems*, 2017

ŠKVORC, Tadej, LAVRAČ, Nada, ROBNIK ŠIKONJA, Marko. Co-bidding graphs for constrained paper clustering. *5th Symposium on Languages, Applications and Technologies : SLATE'16*, 2016, str. 1-13

ŽITNIK, Lovro, ROBNIK ŠIKONJA, Marko. Ebook recommendations based on stylistic features. *V IS 2016*, str. 40-43, 2016



Psihologija sreče

- kaj nas osrečuje?
- korpus 100,000 zapisov o tem kaj nas osrečuje
- pridobljeno z množičenjem AMT
- vsak opiše tri srečne trenutke
- v zadnjih 24 urah ali zadnjih 3 mesecih
- večinoma med 20 in 40 let in samski
- besedilna analiza: 9 kategorij, npr. dosežki, naklonjenost, šport
- razlike med kratkoročnimi in dolgoročnimi srečnimi trenutki, demografske, med spoloma itd.




Akari Asai, Sara Evensen, Behzad Golshan, Alon Halevy, Vivian Li, Andrei Lopatenko, Daniela Stepanov, Yoshihiko Suhara, Wang-Chiew Tan, Yinzhan Xu: HappyDB: A Corpus of 100,000 Crowdsourced Happy Moments. arXiv:1801.07746v2




Razlaga modelov strojnega učenja

Data set: onko; model: PRBF
 $p(\text{recurrence}=1|x) = 0.06$; true recurrence=2



napovedovanje ponovitve raka



napovedovanje uspešnosti prodajnih priložnosti



Zaključki

- nove možnosti pridobivanja informacij iz slik, zvoka in besedil
- številne nove metodološke, etične in družbene dileme
- možna pristranost naučenih modelov zaradi statistično pristranih vzorcev, pristranega vzorčenja, algoritmičnih pristranosti, itd.
- parcialni pristopi, ker nimamo modelov za predstavitev celovitega znanja,
- redefinicije intelligence,
- velike možnosti sodelovanja.