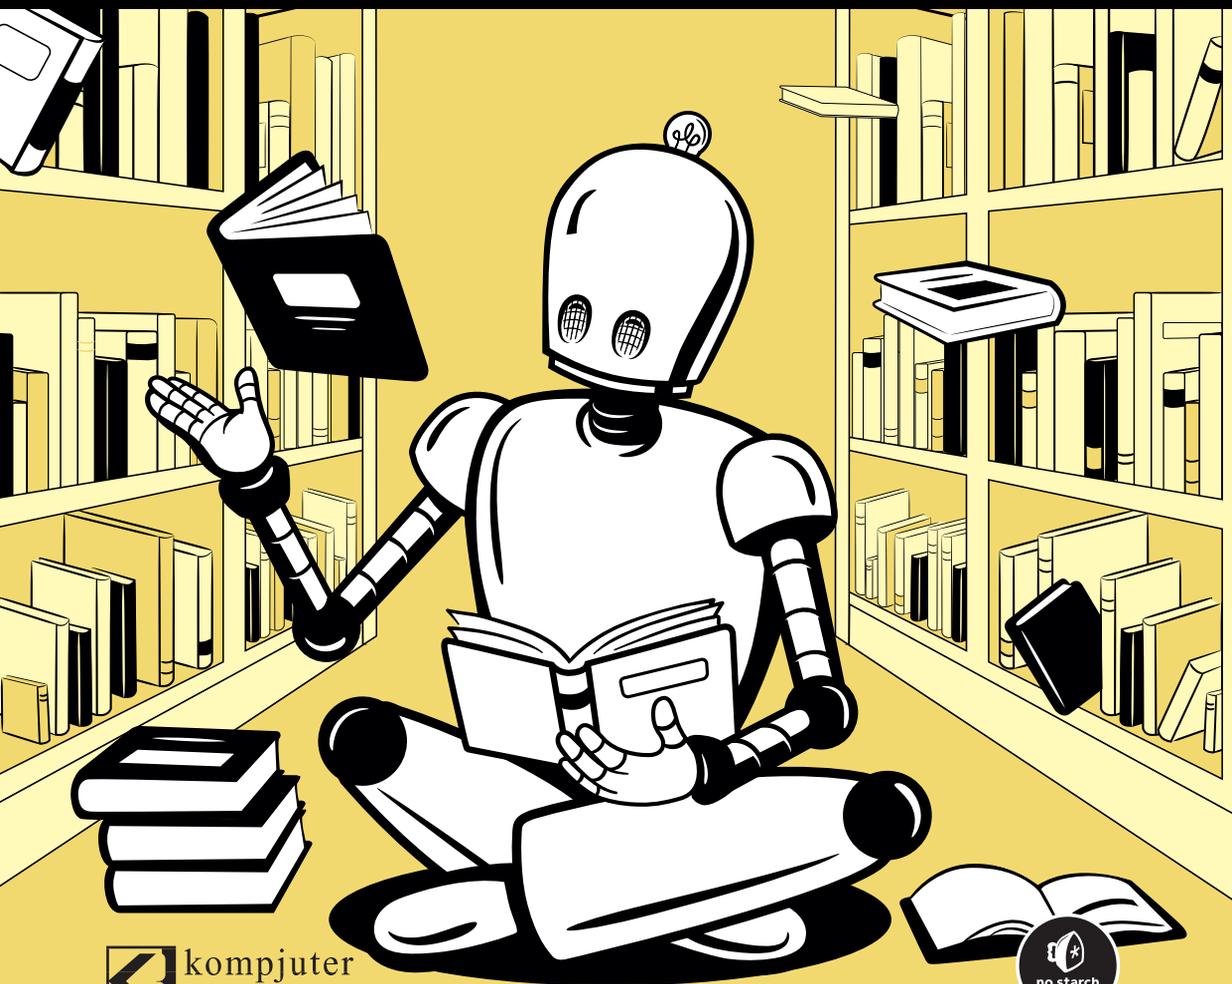
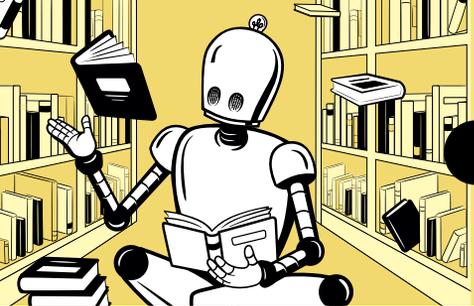


# MAŠINSKO UČENJE I VEŠTAČKA INTELIGENCIJA

30 OSNOVNIH PITANJA I ODGOVORA

SEBASTIJAN RAŠKA





## „POSLE OSNOVA“

IZ PREGGOVORA KRISA ALBONA,  
DIREKTORA MAŠINSKOG UČENJA FONDACIJE WIKIMEDIA

Ako želite da se upustite u detaljnije istraživanje mašinskog učenja, dubokog učenja i veštačke inteligencije, knjiga *Pitanja o mašinskom učenju i veštačkoj inteligenciji*, organizovana u stilu pitanje-odgovor, vam omogućava jednostavan pristup temama, bez mnogo mučenja.

Knjiga je nastala kao odgovor na pitanja koja autor Sebastijan Raška često postavlja, a njen direktan pristup čini napredne teme dostupnijim i zaista zanimljivim. U svakom kratkom, samostalnom poglavlju postavljeno je neko od osnovnih pitanja u vezi sa veštačkom inteligencijom i razmotreno jasnim objašnjenjima, dijagramima i praktičnim vežbama.

### ŠTA SADRŽI:

**FOKUSIRANA POGLAVLJA:** na ključna pitanja u vezi sa veštačkom inteligencijom daju se sažeti odgovori, a složene ideje se razlažu na lako razumljive delove.

**RAZNOVRSNE TEME:** od arhitektura neuronskih mreža i evaluacije modela do računarskog prepoznavanja slika i obrade prirodnog jezika.

**PRAKTIČNE PRIMENE:** tehnike za poboljšanje performansi modela, fino podešavanje velikih modela i još mnogo toga.

Takođe ćete istražiti:

- Upravljanje različitim izvorima slučajnosti pri obuci neuronskih mreža
- Razlike arhitektura kodera i dekodera u velikim jezičkim modelima
- Smanjivanje prilagodavanja modifikacijama podataka i modela

- Konstruisanje intervala poverenja za klasifikatore i optimizovanje modela sa ograničenim označenim podacima
- Kako da izaberete između različitih paradigmi obuke sa više GPU komponenti i različitih tipova generativnih modela veštačke inteligencije
- Koncept metrika performansi za obradu prirodnog jezika
- Koncept induktivne pristrasnosti u vizuelnim transformatorima

Ako ste u potrazi za savršenim izvorom unapređenja svog razumevanja mašinskog učenja, uz knjigu *Pitanja o mašinskom učenju i veštačkoj inteligenciji* granica osnovnog poznavanja veštačke inteligencije ostaće daleko iza vas.

### Biografija autora

Sebastijan Raška, doktor nauka, istraživač je u oblasti mašinskog učenja i veštačke inteligencije, sa strašću za obrazovanjem. Kao glavni instruktor za veštačku inteligenciju u kompaniji Lightning AI, uzbuđen je zbog toga što veštačku inteligenciju i duboko učenje čini dostupnijim. Raška je prethodno bio docent na Departmanu za statistiku Univerziteta Viskonsina u Medisonu, gde se specijalizovao za istraživanje dubokog učenja i mašinskog učenja. Autor je bestslera „*Python mašinsko učenje*“ i „*Mašinsko učenje uz PyTorch i Scikit-Learn*“, koje je na srpski jezik prevela i objavila Kompjuter biblioteka. Više informacija o njegovim istraživanjima nalazi se na njegovom veb sajtu, na adresi <https://sebastianraschka.com>.

# MAŠINSKO UČENJE I VEŠTAČKA INTELIGENCIJA

30 OSNOVNIH PITANJA I ODGOVORA

SEBASTIJAN RAŠKA

 kompjuter  
biblioteka



Izdavač:



Obalskih radnika 4a  
Beograd, Srbija

Tel: 011/2520272

e-pošta: kombib@gmail.com

web-sajt: www.kombib.rs

Za izdavača:

Mihailo J. Šolajić, direktor

Autor: Sebastijan Raška

Prevod: Nemanja Lukić

Recenzent: Miroslav Ristić

Slog: Zvonko Aleksić

Znak Kompjuter biblioteke:

Miloš Milosavljević

Štampa: „Pekograf“, Zemun

Tiraž: 500

Godina izdanja: 2024.

Broj knjige: 578

Izdanje: Prvo

ISBN: 978-86-7310-601-4

Naslov originala:

**MACHINE LEARNING Q AND AI.**  
Copyright © 2024 by Sebastian Raschka

ISBN: 978-1-7185-0376-2

No Starch Press, Inc.  
245 8th Street, San Francisco, CA 94103  
phone: 1.415.863.9900  
www.nostarch.com

## **MAŠINSKO UČENJE I VEŠTAČKA INTELIGENCIJA**

**Autorizovani prevod sa engleskog jezika.**

Sva prava zadržana. Nijedan deo ove knjige se ne sme reprodukovati, čuvati u sistemu za pronalaženje ili prenositi u bilo kom obliku ili na bilo koji način, bez prethodne pismene dozvole izdavača, osim u slučaju kratkih citata ugrađenih u kritičke članke ili prikaze.

Tokom pripreme ove knjige uloženi su svi naponi da se obezbedi tačnost predstavljenih informacija. Međutim, informacije sadržane u ovoj knjizi se prodaju bez garancije, bilo izričite ili podrazumevane. Autori i izdavač neće biti odgovorni za bilo kakvu štetu prouzrokovanu ili navodno prouzrokovanu direktno ili indirektno ovom knjigom.

„Kompjuter biblioteka” i „No Starch Press, Inc.” su nastojali da obezbede informacije o zaštitnim znakovima o svim kompanijama i proizvodima pomenutim u ovoj knjizi korišćenjem odgovarajućeg načina njihovog pominjanja u tekstu. Međutim, ne možemo da garantujemo tačnost ovih informacija.

CIP - Каталогизација у публикацији  
Народна библиотека Србије, Београд

004.8

**РАШКА, Себастијан, 1988-**

**Машино учење и вештачка интелигенција:** 30 основних питања и одговора / Sebastian Raschka; [prevod Nemanja Lukić]. - 1. izd. - Beograd: Kompjuter Biblioteka, 2024 (Zemun : Pekograf). - XXV, 234 str.: ilustr.; 24 cm. - (Kompjuter biblioteka ; br. knj. 578)

Prevod dela: Machine Learning Q and AI. - Tiraž 500. - O autoru: str. III. - Registar.

ISBN 978-86-7310-601-4

a) Вештачка интелигенција  
b) Машинско учење

COBISS.SR-ID 146563081

## O AUTORU

**Sebastijan Raška**, doktor nauka, istraživač je u oblastima mašinskog učenja i veštačke inteligencije, sa strašću za obrazovanjem. Kao glavni instruktor za veštačku inteligenciju u kompaniji Lightning AI, uzbuđen je zbog toga što veštačku inteligenciju i duboko učenje čini dostupnijim. Raška je prethodno bio docent na Departmanu za statistiku Univerziteta Viskonsina u Medisonu, gde se specijalizovao za istraživanje dubokog učenja i mašinskog učenja. Autor je bestselera „*Python mašinsko učenje*” i „*Mašinsko učenje uz PyTorch i Scikit-Learn*”, koje je na srpski jezik prevela i objavila Kompjuter biblioteka. Više informacija o njegovim istraživanjima nalazi se na njegovom veb sajtu, na adresi <https://sebastianraschka.com>.

## O TEHNIČKOM RECENZENTU

**Andrea Panica** je glavni stručnjak za veštačku inteligenciju u kompaniji Baker Hughes, koji koristi najsavremenije tehnike veštačke inteligencije i mašinskog učenja da bi ubrzao dizajn inženjerskih rešenja, automatizovao prikupljanje i izvlačenje informacija iz velikih kolekcija dokumenata, i koristi računarsko prepoznavanje slika za inspekciju bespilotnih objekata. Ima doktorat iz računarske dinamike fluida. Pre pridruživanja kompaniji Baker Hughes, radio je kao istraživač za računarsku dinamiku fluida u Italijanskom istraživačkom centru za vazduhoplovstvo CIRA.



# Kratak sadržaj

UVOD.....	xxvii
<b>DEO1</b>	
NEURONSKE MREŽE I DUBOKO UČENJE .....	1
<b>POGLAVLJE 1</b>	
UGRAĐENI VEKTORI, LATENTNI PROSTOR I REPREZENTACIJE.....	3
<b>POGLAVLJE 2</b>	
SAMONADGLEDANO UČENJE.....	9
<b>POGLAVLJE 3</b>	
UČENJE SA MALO PRIMERA .....	15
<b>POGLAVLJE 4</b>	
HIPOTEZA O DOBITNOJ SREĆKI.....	19
<b>POGLAVLJE 5</b>	
SMANJIVANJE PREPRILAGOĐAVANJA POMOĆU PODATAKA .....	23
<b>POGLAVLJE 6</b>	
SMANJIVANJE PREPRILAGOĐAVANJA MODIFIKACIJAMA MODELA .....	29
<b>POGLAVLJE 7</b>	
PARADIGME OBUKE SA VIŠE GPU KOMPONENTI .....	37
<b>POGLAVLJE 8</b>	
USPEH TRANSFORMATORA .....	43

**POGLAVLJE 9**

GENERATIVNI MODELI VEŠTAČKE INTELIGENCIJE ..... 49

**POGLAVLJE 10**

IZVORI SLUČAJNOSTI ..... 59

**DEO 2**

RAČUNARSKO PREPOZNAVANJE SLIKA ..... 67

**POGLAVLJE 11**

IZRAČUNAVANJE BROJA PARAMETARA ..... 69

**POGLAVLJE 12**

POTPUNO POVEZANI I KONVOLUCIONI SLOJEVI ..... 75

**POGLAVLJE 13**

VELIKI SKUPOVI ZA OBUKU VIZUELNIH TRANSFORMATORA ..... 79

**DEO 3**

OBRADA PRIRODNOG JEZIKA ..... 87

**POGLAVLJE 14**

DISTRIBUCIONA HIPOTEZA ..... 89

**POGLAVLJE 15**

POVEĆANJE PODATAKA ZA TEKST ..... 93

**POGLAVLJE 16**

SAMOPAŽNJA ..... 99

**POGLAVLJE 17**

TRANSFORMATORI U SMISLU KODERA I DEKODERA ..... 105

**POGLAVLJE 18**KORIŠĆENJE I FINO PODEŠAVANJE UNAPRED OBUČENIH  
TRANSFORMATORA ..... 113**POGLAVLJE 19**

EVALUACIJA GENERATIVNIH VELIKIH JEZIČKIH MODELA ..... 127

<b>DEO 4</b>	
PROIZVODNJA I IMPLEMENTACIJA.....	137
<b>POGLAVLJE 20</b>	
OBUKA SA I BEZ STANJA .....	139
<b>POGLAVLJE 21</b>	
VEŠTAČKA INTELIGENCIJA ORIJENTISANA NA PODATKE .....	143
<b>POGLAVLJE 22</b>	
UBRZAVANJE ZAKLJUČIVANJA .....	147
<b>POGLAVLJE 23</b>	
PROMENE U RASPODELI PODATAKA .....	153
<b>DEO 5</b>	
PREDIKTIVNE PERFORMANSE I EVALUACIJA MODELA.....	159
<b>POGLAVLJE 24</b>	
PUASONOVA I ORDINALNA REGRESIJA.....	161
<b>POGLAVLJE 25</b>	
INTERVALI POVERENJA .....	163
<b>POGLAVLJE 26</b>	
INTERVALI POVERENJA NASPRAM KONFORMNA PREDVIĐANJA .....	173
<b>POGLAVLJE 27</b>	
ADEKVATNE METRIKE .....	179
<b>POGLAVLJE 28</b>	
K U K-STRUKO UNAKRSNOJ PROVERI VALJANOSTI.....	185
<b>POGLAVLJE 29</b>	
NESLAGANJE IZMEĐU SKUPA ZA OBUKU I SKUPA ZA TESTIRANJE .....	189
<b>POGLAVLJE 30</b>	
OGRANIČENI OZNAČENI PODACI .....	193
POGOVOR .....	205
DODATAK: ODGOVORI ZA VEŽBE.....	207
INDEKS .....	223



# Sadržaj

<b>PREDGOVOR</b> .....	<b>xxv</b>
<b>ZAHVALNOSTI</b> .....	<b>xxvii</b>
<b>UVOD</b> .....	<b>xxix</b>
Za koga je ova knjiga? .....	xxix
Šta ćete naučiti iz ove knjige.....	xxx
Kako da čitate ovu knjigu.....	xxx
Onlajn resursi.....	xxxiii

## **DEO 1**

<b>NEURONSKE MREŽE I DUBOKO UČENJE</b> .....	<b>1</b>
--	----------

## **POGLAVLJE 1**

<b>UGRAĐENI VEKTORI, LATENTNI PROSTOR I REPREZENTACIJE</b> .....	<b>3</b>
Ugrađeni vektori.....	3
Latentni prostor .....	5
Reprezentacija.....	6
Vežbe .....	6
Literatura.....	7

## **POGLAVLJE 2**

<b>SAMONADGLEDANO UČENJE</b> .....	<b>9</b>
Samonadgledano učenje naspram učenja prenosom znanja .....	9
Korišćenje neoznačenih podataka.....	11
Samopredviđanje i kontrastno samonadgledano učenje.....	11
Vežbe .....	14
Literatura.....	14

**POGLAVLJE 3****UČENJE SA MALO PRIMERA ..... 15**

Skupovi podataka i terminologija.....	15
Vežbe.....	18

**POGLAVLJE 4****HIPOTEZA O DOBITNOJ SREĆKI ..... 19**

Postupak obuke sa dobitnom srećkom.....	19
Praktične implikacije i ograničenja.....	20
Vežbe.....	21
Literatura.....	21

**POGLAVLJE 5****SMANJIVANJE PREPRILAGOĐAVANJA POMOĆU PODATAKA ..... 23**

Uobičajeni metodi.....	24
Sakupljanje dodatnih podataka.....	24
Povećavanje podataka.....	24
Predobuka.....	25
Drugi metodi.....	26
Vežbe.....	26
Literatura.....	26

**POGLAVLJE 6****SMANJIVANJE PREPRILAGOĐAVANJA MODIFIKACIJAMA MODELA ..... 29**

Uobičajeni metodi.....	30
Regularizacija.....	30
Manji modeli.....	31
Upozorenja pri korišćenju manjih modela.....	32
Metodi ansambla.....	33
Drugi metodi.....	34
Izbor tehnike regularizacije.....	35
Vežbe.....	35
Literatura.....	35

**POGLAVLJE 7****PARADIGME OBUKE SA VIŠE GPU KOMPONENTI ..... 37**

Paradigme obuke.....	38
Paralelizam modela.....	38
Paralelizam podataka.....	38
Paralelizam tenzora.....	38
Paralelizam protočnih struktura.....	40
Paralelizam nizova.....	40
Preporuke.....	41
Vežbe.....	42
Literatura.....	42

**POGLAVLJE 8**

<b>USPEH TRANSFORMATORA .....</b>	<b>43</b>
Mehanizam pažnje .....	43
Predobuka pomoću samonadgledanog učenja .....	45
Veliki broj parametara .....	45
Jednostavna paralelizacija .....	45
Vežbe .....	46
Literatura .....	47

**POGLAVLJE 9**

<b>GENERATIVNI MODELI VEŠTAČKE INTELIGENCIJE .....</b>	<b>49</b>
Generativno naspram diskriminativnog modelovanja .....	49
Vrste dubokih generativnih modela .....	50
Modeli zasnovani na energiji .....	50
Varijacioni autokodori .....	51
Generativne suparničke mreže .....	52
Modeli zasnovani na toku .....	53
Autoregresivni modeli .....	54
Difuzioni modeli .....	55
Modeli postojanosti .....	56
Preporuke .....	57
Vežbe .....	57
Literatura .....	58

**POGLAVLJE 10**

<b>IZVORI SLUČAJNOSTI .....</b>	<b>59</b>
Inicijalizacija težina modela .....	59
Uzorkovanje i mešanje skupa podataka .....	60
Nedeterministički algoritmi .....	61
Različiti algoritmi izvršavanja .....	61
Hardver i upravljački programi .....	62
Slučajnost i generativna veštačka inteligencija .....	62
Vežbe .....	64
Literatura .....	65

**DEO 2**

<b>RAČUNARSKO PREPOZNAVANJE SLIKA .....</b>	<b>67</b>
---	-----------

**POGLAVLJE 11**

<b>IZRAČUNAVANJE BROJA PARAMETARA .....</b>	<b>69</b>
Kako pronaći broj parametara .....	69
Konvolucionni slojevi .....	70
Potpuno povezani slojevi .....	72
Praktične primene .....	73
Vežbe .....	73

**POGLAVLJE 12**

<b>POTPUNO POVEZANI I KONVOLUCIONI SLOJEVI .....</b>	<b>75</b>
Kada su veličine jezgra i ulaza jednake .....	76
Kada je veličina jezgra jednaka 1 .....	77
Preporuke .....	78
Vežbe .....	78

**POGLAVLJE 13**

<b>VELIKI SKUPOVI ZA OBUKU VIZUELNIH TRANSFORMATORA .....</b>	<b>79</b>
Induktivne pristrasnosti u konvolucionim neuronskim mrežama .....	80
Vizuelni transformatori mogu da nadmaše konvolucione neuronske mreže .....	82
Induktivne pristrasnosti u vizuelnim transformatorima .....	83
Preporuke .....	84
Vežbe .....	85
Literatura .....	85

**DEO 3**

<b>OBRADA PRIRODNOG JEZIKA .....</b>	<b>87</b>
--------------------------------------	-----------

**POGLAVLJE 14**

<b>DISTRIBUCIONA HIPOTEZA .....</b>	<b>89</b>
Word2vec, BERT i GPT .....	90
Da li hipoteza važi? .....	92
Vežbe .....	92
Literatura .....	92

**POGLAVLJE 15**

<b>POVEĆANJE PODATAKA ZA TEKST .....</b>	<b>93</b>
Zamena sinonima .....	93
Brisanje reči .....	94
Zamena pozicija reči .....	94
Mešanje rečenica .....	95
Umetanje šuma .....	95
Povratno prevođenje .....	96
Veštački generisani podaci .....	96
Preporuke .....	97
Vežbe .....	97
Literatura .....	98

**POGLAVLJE 16**

<b>SAMOPAŽNJA .....</b>	<b>99</b>
Pažnja u rekurentnim neuronskim mrežama .....	99
Mehanizam samopažnje .....	101
Vežbe .....	103
Literatura .....	103

<b>POGLAVLJE 17</b>	<b>105</b>
<b>TRANSFORMATORI U SMISLU KODERA I DEKODERA .....</b>	<b>105</b>
Originalan transformator .....	105
Koderi.....	107
Dekoderi .....	108
Koder-dekoder hibridi.....	110
Terminologija .....	110
Savremeni modeli transformatora.....	111
Vežbe .....	112
Literatura.....	112
<b>POGLAVLJE 18</b>	<b>113</b>
<b>KORIŠĆENJE I FINO PODEŠAVANJE UNAPRED OBUČENIH TRANSFORMATORA .....</b>	<b>113</b>
Korišćenje transformatora za zadatke klasifikacije .....	114
Učenje u kontekstu, indeksiranje i podešavanje upita.....	116
Efikasno fino podešavanje parametara.....	119
Učenje potkrepljivanjem na osnovu Ijudske povratne informacije.....	124
Prilagođavanje predobučениh jezičkih modela .....	124
Vežbe .....	125
Literatura.....	125
<b>POGLAVLJE 19</b>	<b>127</b>
<b>EVALUACIJA GENERATIVNIH VELIKIH JEZIČKIH MODELA .....</b>	<b>127</b>
Metrike evaluacije za velike jezičke modele.....	127
Perpleksnost.....	128
BLEU metrike.....	129
ROUGE metrike.....	131
BERTScore metrike .....	132
Zamenske metrike .....	133
Vežbe .....	134
Literatura.....	134
<b>DEO 4</b>	
<b>PROIZVODNJA I IMPLEMENTACIJA .....</b>	<b>137</b>
<b>POGLAVLJE 20</b>	
<b>OBUKA SA I BEZ STANJA .....</b>	<b>139</b>
(Pre)obuka bez stanja .....	139
Obuka sa stanjem.....	140
Vežbe .....	141

**POGLAVLJE 21****VEŠTAČKA INTELIGENCIJA ORIJENTISANA NA PODATKE ..... 143**

Veštačka inteligencija orijentisana na podatke naspram veštačke inteligencije orijentisane na modele .....	143
Preporuke .....	145
Vežbe .....	146
Literatura .....	146

**POGLAVLJE 22****UBRZAVANJE ZAKLJUČIVANJA ..... 147**

Paralelizacija.....	147
Vektorizacija.....	148
Razlaganje petlji .....	149
Fuzija operacija .....	150
Kvantizacija .....	151
Vežbe .....	152
Literatura .....	152

**POGLAVLJE 23****PROMENE U RASPODELI PODATAKA ..... 153**

Promena kovarijata .....	153
Promena oznaka.....	154
Promena koncepta .....	155
Promena domena .....	155
Vrste promena raspodela podataka.....	156
Vežbe .....	157
Literatura .....	157

**DEO 5****PREDIKTIVNE PERFORMANSE I EVALUACIJA MODELA..... 159****POGLAVLJE 24****PUASONOVA I ORDINALNA REGRESIJA..... 161**

Vežbe .....	162
-------------	-----

**POGLAVLJE 25****INTERVALI POVERENJA ..... 163**

Definisanje intervala poverenja .....	164
Metodi .....	166
Metod 1: Aproksimacija normalnom raspodelom .....	166
Metod 2: Uzorkovanje sa ponavljanjem skupova za obuku .....	167
Metod 3: Uzorkovanje sa ponavljanjem predviđanja skupova testova.....	169
Metod 4: Ponovno obučavanje modela sa slučajnim početnim vrednostima .....	169
Preporuke .....	170
Vežbe .....	171
Literatura .....	171

**POGLAVLJE 26****INTERVALI POVERENJA NASPRAM KONFORMNA PREDVIĐANJA ..... 173**

Intervali poverenja i intervali predviđanja .....	174
Intervali predviđanja i konformna predviđanja .....	174
Oblasti, intervali i skupovi predviđanja .....	174
Izračunavanje konformnih predviđanja .....	175
Primer konformnog predviđanja .....	176
Pogodnosti konformnih predviđanja .....	177
Preporuke .....	178
Vežbe .....	178
Literatura .....	178

**POGLAVLJE 27****ADEKVATNE METRIKE ..... 179**

Kriterijumi .....	179
Srednje-kvadratna greška .....	180
Gubitak unakrsne entropije .....	182
Vežbe .....	183

**POGLAVLJE 28****K U K-STRUKO UNAKRSNOJ PROVERI VALJANOSTI..... 185**

Kompromisi pri odabiru vrednosti za k .....	186
Utvrđivanje odgovarajućih vrednosti za k .....	187
Vežbe .....	188
Literatura .....	188

**POGLAVLJE 29****NESLAGANJE IZMEĐU SKUPA ZA OBUKU I SKUPA ZA TESTIRANJE ..... 189**

Vežbe .....	191
-------------	-----

**POGLAVLJE 30****OGRANIČENI OZNAČENI PODACI ..... 193**

Unapređivanje performansi modela sa ograničenim brojem označenih podataka .....	193
Označavanje dodatnih podataka .....	193
Uzorkovanje sa ponavljanjem podataka .....	194
Učenje sa potkrepljivanjem .....	194
Samonadgledano učenje .....	194
Aktivno učenje .....	195
Učenje sa malo primera .....	195
Metaučenje .....	196
Slabo nadgledano učenje .....	197
Polunadgledano učenje .....	198
Samoobuka .....	199
Istovremeno učenje za više problema .....	199
Multimodalno učenje .....	200
Induktivne pristrasnosti .....	202

Preporuke .....	202
Vežbe .....	204
Literatura .....	204

**POGOVOR** **205**

**DODATAK: ODGOVORI ZA VEŽBE** **207**

Poglavlje 1 .....	207
Poglavlje 2 .....	208
Poglavlje 3 .....	208
Poglavlje 4 .....	209
Poglavlje 5 .....	209
Poglavlje 6 .....	210
Poglavlje 7 .....	210
Poglavlje 8 .....	211
Poglavlje 9 .....	211
Poglavlje 10.....	212
Poglavlje 11.....	212
Poglavlje 12.....	213
Poglavlje 13.....	213
Poglavlje 14.....	214
Poglavlje 15.....	214
Poglavlje 16.....	215
Poglavlje 17.....	215
Poglavlje 18.....	216
Poglavlje 19.....	216
Poglavlje 20.....	217
Poglavlje 21.....	217
Poglavlje 22.....	218
Poglavlje 23.....	218
Poglavlje 24.....	219
Poglavlje 25.....	219
Poglavlje 26.....	219
Poglavlje 27.....	220
Poglavlje 28.....	221
Poglavlje 29.....	221
Poglavlje 30.....	222

**INDEKS** **223**

# PREDGOVOR

Postoji na stotine uvodnih tekstova o mašinskom učenju. Dolaze u raznovrsnom nizu stilova i pristupa, od teorijskih perspektiva za studente postdiplomskih studija do poslovnih gledišta usmerenih ka izvršnom menadžmentu. Ovi uvodi su neprocenjivi resursi za pojedince koji prave svoje prve korake u ovom polju, a tako će ostati i u decenijama koje dolaze.

Međutim, put ka stručnosti se ne završava na početku. Takođe, obuhvata komplikovane obilaznice, strmije uspone i nijanse koje nisu odmah očigledne. Drugim rečima, nakon proučavanja osnova, učenici se pitaju: „Šta dalje”? Baš tu, izvan osnova, ova knjiga ima svoju svrhu.

Ovom knjigom, Sebastijan vodi čitaoce kroz širok spektar srednjih i naprednih tema o primenjenom mašinskom učenju, s kojima će se verovatno susresti na svom putu ka stručnosti. Teško je naći boljeg vodiča od Sebastijana, koji je trenutno, bez preterivanja, najbolji instruktor mašinskog učenja. Na svakoj stranici Sebastijan prenosi svoje obimno znanje, deli strast i radoznalost, koji obeležavaju istinsku stručnost.

Svim učenicima koji su prešli početni prag i žele dublje znanje, ovo je knjiga za vas. Kad pročitate ovu knjigu bićete veštiji stručnjak za mašinsko učenje nego što ste bili do tad. Neka vam ona posluži kao most ka vašoj sledećoj fazi uzbudljivih avantura u mašinskom učenju.

Srećno!

Kris Albon  
direktor mašinskog učenja, fondacija Wikimedia  
San Francisko  
Avgust, 2023.



# ZAHVALNOSTI

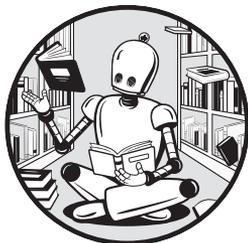
Pisanje knjige je ogroman poduhvat. Ovaj projekat ne bi bio moguć bez pomoći zajednica otvorenog koda i mašinskog učenja, koje su zajedno stvorile tehnologije o kojima se u ovoj knjizi govori.

Želim da izrazim zahvalnost sledećim ljudima na izuzetno korisnim povratnim informacijama o rukopisu:

- Andrei Panici, za izuzetnu tehničku recenziju, koja je pružila veoma vredne i pronicljive povratne informacije.
- Antonu Rešetnikovu, za sugestiju čistijeg rasporeda za dijagram toka nadgledanog učenja u poglavlju 30.
- Nikanu Dustiju, Huanu M. Belo-Rivasu i Kenu Hofmanu, za otkrivanje raznih štamparskih grešaka.
- Abigejl Šot-Rozenfild i Džil Frenklin, što su uzorne urednice. Njihova sposobnost za postavljanje pravih pitanja i unapređivanje jezika značajno je podiglo kvalitet ove knjige.



# UVOD



ZAHVALJUJUĆI BRZOM NAPRETKU DUBOKOG UČENJA, NEKOLIKO POSLEDNIJH GODINA SMO SVEDOCI ZNAČAJNOG RAZVOJA MAŠINSKOG UČENJA I VEŠTAČKE INTELIGENCIJE

Ovaj napredak je uzbudljiv, ako očekujemo da ovi pomaci stvore nove industrije, transformišu postojeće i poboljšaju kvalitet života ljudi širom sveta. Nasuprot tome, konstantno pojavljivanje novih tehnika može predstavljati izazov i zahtevati dosta vremena da bismo ostali informisani o najnovijim dostignućima. Međutim, upućenost je od suštinskog značaja za stručnjake i organizacije koje se oslanjaju na ove tehnologije.

Napisao sam ovu knjigu kao resurs za čitaoce i stručnjake mašinskog učenja koji žele da unaprede svoju stručnost u ovom polju i da uče o tehnikama koje smatram korisnim i značajnim, ali koje često prolaze neprimećene u tradicionalnim uvodnim udžbenicima i predavanjima. Nadam se da će vam ova knjiga biti dragocen izvor za sticanje novih uvida i otkrivanje novih tehnika koje možete primeniti u svom radu.

## Za koga je ova knjiga?

Snalaženje u svetu literature o veštačkoj inteligenciji i mašinskom učenju često deluje kao hodanje po žici, s obzirom na to da većina knjiga pripada jednoj od krajnosti: opširni uvodi za početnike ili dubokoumna matematička razmatranja. Ova knjiga ilustruje i razmatra važne napretke u ovim oblastima, a istovremeno je pristupačna i ne zahteva napredno matematičko ili programersko znanje.

Ova knjiga je namenjena osobama koje imaju određeno iskustvo o mašinskom učenju i žele da nauče nove koncepte i tehnike. Idealna je za one koji su pohađali početni kurs iz mašinskog učenja ili dubokog učenja, ili su pročitali ekvivalentnu uvodnu knjigu na tu temu. (U ovoj knjizi ću koristiti termin *mašinsko učenje* kao opšti pojam koji obuhvata mašinsko učenje, duboko učenje i veštačku inteligenciju.)

## Šta ćete naučiti iz ove knjige

Ova knjiga usvaja jedinstveni stil pitanja i odgovora, gde je svako kratko poglavlje organizovano oko centralnog pitanja koje se odnosi na osnovne koncepte mašinskog učenja, dubokog učenja i veštačke inteligencije. Svako pitanje je praćeno detaljnim objašnjenjem, ilustracijama i slikama, kao i vežbama za proveru stečenog znanja. Mnoga poglavlja, takođe, sadrže reference izvora za dalje čitanje. Ove kompaktne informacije predstavljaju dobru polaznu tačku na vašem putu od početnika do stručnjaka za mašinsko učenje.

Knjiga obrađuje širok spektar tema. Novi uvidi o ustaljenim arhitekturama, poput konvolucionih mreža, vam omogućavaju efikasniju upotrebu ovih tehnologija. Takođe se razmatraju naprednije tehnike, poput unutrašnjih mehanizama velikih jezičkih modela (LLM) i vizuelnih transformatora. Čak će i iskusni istraživači i stručnjaci mašinskog učenja naići na neku novu tehniku koju mogu dodati svom arsenalu.

Iako će vam predstaviti nove koncepte i ideje, ovo nije knjiga o matematici ili kodiranju. Dok je budete čitali, nećete morati da izvodite nikakve dokaze, niti da pokrećete bilo kakav kod. Drugim rečima, ova knjiga je savršen saputnik, ili štivo koje ćete čitati na svojoj omiljenoj fotelji, uz jutarnju kafu ili čaj.

## Kako da čitate ovu knjigu

Svako poglavlje ove knjige je osmišljeno tako da bude samostalno, što vam daje slobodu da prelazite sa teme na temu, po volji. Kada je koncept iz jednog poglavlja detaljnije objašnjen u drugom, postoje reference poglavlja koje možete pratiti da biste popunili praznine u svom znanju.

Međutim, u pitanju je strateški redosled poglavlja. Na primer, rano poglavlje o ugrađenim vektorima postavlja osnovu za kasnija razmatranja o samonadgledanom učenju i učenju sa malo primera. Za najbolje iskustvo čitanja i najpotpunije razumevanje sadržaja, preporučujem da knjigu pročitate od početka do kraja.

Svako poglavlje sadrži opcione vežbe, za čitaoce koji žele da provere stečeno znanje, a njihova rešenja nalaze se na kraju knjige. Pored toga, za sve radove koji su citirani u nekom poglavlju, ili za čitanje dodatne literature na temu tog poglavlja, potpune informacije se nalaze u odeljku „Literatura”, na kraju poglavlja.

Knjiga je podeljena na pet glavnih delova koji su fokusirani na najvažnije aktuelne teme o mašinskom učenju i veštačkoj inteligenciji.

**Deo I: Neuronske mreže i duboko učenje** pokreće pitanja o dubokim neuronskim mrežama i dubokom učenju koja nisu specifična za određeni poddomen. Na primer, razmatramo alternative nadgledanom učenju i tehnike za smanjivanje preprilagođavanja, što je ustaljen problem prilikom korišćenja modela mašinskog učenja za rešavanje realnih problema, kada su podaci ograničeni.

**Poglavlje 1: Ugrađeni vektori, latentni prostor i reprezentacije** Razmatra razlike i sličnosti između ugrađenih vektora, latentnih vektora i reprezentacija. Objašnjava kako ovi koncepti pomažu u kodiranju informacija u kontekstu mašinskog učenja.

**Poglavlje 2: Samonadgledano učenje** Fokusirano je na samonadgledano učenje, metod koji omogućava neuronskim mrežama da koriste velike skupove neoznačenih podataka na nadgledan način.

**Poglavlje 3: Učenje sa malo primera** Predstavlja učenje sa malo primera, specijalizovanu tehniku nadgledanog učenja prilagođenu za male skupove podataka za obuku.

**Poglavlje 4: Hipoteza o dobitnoj sreći** Istražuje ideju da slučajno inicijalizovane neuronske mreže sadrže manje, efikasnije pod mreže.

**Poglavlje 5: Smanjivanje preprilagodavanja pomoću podataka** Bavi se izazovom preprilagodavanja u mašinskom učenju, razmatranjem strategija usmerenih na povećavanje podataka i korišćenje neoznačenih podataka radi smanjenja preprilagodavanja.

**Poglavlje 6: Smanjivanje preprilagodavanja modifikacijama modela** Proširuje temu o preprilagodavanju, sa fokusom na rešenja vezana za model, kao što su regularizacija, izbor jednostavnijih modela i tehnike ansambla.

**Poglavlje 7: Paradigme obuke sa više GPU komponenti** Objašnjava različite paradigme obuke za postavke sa više GPU komponenti, radi ubrzanja obuke modela, uključujući paralelizam podataka i modela.

**Poglavlje 8: Uspeh transformatora** Istražuje popularnu arhitekturu transformatora, ističući karakteristike kao što su mehanizmi pažnje, jednostavnost paralelizacije i veliki broj parametara.

**Poglavlje 9: Generativni modeli veštačke inteligencije** Pruža sveobuhvatan pregled dubokih generativnih modela, koji služe za kreiranje različitih medijskih formata, uključujući slike, tekst i audio. Razmatra prednosti i nedostatke svake vrste modela.

**Poglavlje 10: Izvori slučajnosti** Apostrofira različite izvore slučajnosti u obuci dubokih neuronskih mreža koji mogu dovesti do nekonzistentnih i ne-reproduktivnih rezultata, kako tokom obuke tako i tokom zaključivanja. Iako slučajnost može biti nenamerna, može se uvesti i namerno, dizajnom.

**Deo II: Računarsko prepoznavanje slika** fokusirano je na teme vezane uglavnom za duboko učenje, ali specifične za računarsko prepoznavanje slika, među kojima mnoge obuhvataju konvolucione neuronske mreže i vizuelne transformatore.

**Poglavlje 11: Izračunavanje broja parametara** Objašnjava postupak određivanja parametara u konvolucionoj neuronskoj mreži, što je korisno za procenu skladišnih i memorijskih zahteva modela.

**Poglavlje 12: Potpuno povezani i konvolucioni slojevi** Ilustruje situacije u kojima konvolucioni slojevi mogu, bez problema, da zamene potpuno povezane slojeve, što može biti korisno za optimizaciju hardvera ili pojednostavljenje implementacija.

**Poglavlje 13: Veliki skupovi za obuku vizuelnih transformatora** Istražuje razloge zbog kojih vizuelni transformatori zahtevaju obimnije skupove podataka za obuku, u poređenju sa konvencionalnim konvolucionim neuronskim mrežama.

**Deo III: Obrada prirodnog jezika** obuhvata teme koje se tiču rada sa tekstem, od kojih su mnoge povezane sa arhitekturama transformatora i samopažnjom.

**Poglavlje 14: Distribucionna hipoteza** Istražuje distribucionu hipotezu, lingvističku teoriju koja sugeriše da reči koje se pojavljuju u istim kontekstima obično imaju slična značenja, što ima korisne implikacije za obuku modela mašinskog učenja.

**Poglavlje 15: Povećanje podataka za tekst** Ističe značaj povećavanja podataka za tekst, tehniku koja se koristi za veštačko povećavanje veličine skupa podataka, što može pomoći u poboljšanju performansi modela.

**Poglavlje 16: Samopažnja** Uvodi samopažnju, mehanizam koji omogućava svakom segmentu ulaza neuronske mreže da se referiše na druge delove. Samopažnja je ključni mehanizam u modernim velikim jezičkim modelima.

**Poglavlje 17: Transformatori u smislu kodera i dekodera** Opisuje nijanse arhitekture transformatora u smislu kodera i dekodera i objašnjava koji tip arhitekture je najkorisniji za svaki jezički zadatak obrade.

**Poglavlje 18: Korišćenje i fino podešavanje unapred obučениh transformatora** Objasnjava različite metode za fino podešavanje unapred obučениh velikih jezičkih modela i razmatra njihove prednosti i nedostatke.

**Poglavlje 19: Evaluacija generativnih velikih jezičkih modela** Navodi značajne metrike evaluacije za jezičke modele, kao što su perplexnost, BLEU, ROUGE i BERTScore metrike.

**Deo IV: Proizvodnja i implementacija** obuhvata pitanja koja se odnose na praktične scenarije, poput povećanja brzine zaključivanja i različitih vrsta promena raspodele.

**Poglavlje 20: Obuka sa i bez stanja** Ukazuje na razlike između metodologija obuka sa i bez stanja, koje se koriste pri implementaciji modela.

**Poglavlje 21: Veštačka inteligencija orijentisana na podatke** Istražuje veštačku inteligenciju orijentisanu na podatke, koja stavlja akcenat na unapređivanje skupova podataka radi poboljšanja performansi modela. Ovaj pristup je u suprotnosti sa konvencionalnim pristupom orijentisanim na modele, koji naglašava unapređivanje arhitekture ili metoda modela.

**Poglavlje 22: Ubrzavanje zaključivanja** Uvodi tehnike za poboljšanje brzine zaključivanja modela, bez menjanja arhitekture modela ili ugrožavanja tačnosti.

**Poglavlje 23: Promene u raspodeli podataka** Nakon implementacije, modeli veštačke inteligencije mogu se suočiti sa razlikama između raspodela podataka za obuku i raspodela realnih podataka, poznatih kao promene u raspodeli podataka. Ove promene mogu da naruše performanse modela. Ovo poglavlje kategorizuje i detaljnije objašnjava uobičajene promene, poput promene kovarijate, promene koncepta, promene oznake i promene domena.

**Deo V: Prediktivne performanse i evaluacija modela** detaljnije se bavi različitim aspektima izvlačenja prediktivne performanse, poput promene funkcije gubitka, postavljanja  $k$ -strukne unakrsne provere valjanosti i suočavanja sa ograničenim označenim podacima.

**Poglavlje 24: Puasonova i ordinalna regresija** Ističe razlike između Puasonove i ordinalne regresije. Puasonova regresija je pogodna za prebrojive podatke koji prate Puasonovu raspodelu, kao što je broj prehlada dobijenih u avionu. Nasuprot tome, ordinalna regresija obrađuje uređene kvalitativne podatke bez pretpostavke o jednakoj udaljenosti kategorija, kao što je težina bolesti.

**Poglavlje 25: Intervali poverenja** Bavi se metodama za konstrukciju intervala poverenja za klasifikatore mašinskog učenja. Razmatra svrhu intervala poverenja, raspravlja o tome kako ocenjuju nepoznate parametre populacije i uvodi tehnike poput aproksimacije normalnom raspodelom, uzorkovanja sa ponavljanjem i ponovne obuke sa slučajnim početnim vrednostima.

**Poglavlje 26: Intervali poverenja naspram konformna predviđanja** Raspravlja o razlici između intervala poverenja i konformna predviđanja, opisujući ove poslednje kao alat za kreiranje intervala predviđanja koji pokrivaju stvarne ishode sa određenom verovatnoćom.

**Poglavlje 27: Adekvatne metrike** Fokusira se na osnovna svojstva adekvatne metrike u matematici i računarskim naukama. Ispituje da li uobičajene funkcije gubitka u mašinskom učenju, poput srednje-kvadratne greške i gubitka unakrsne entropije, zadovoljavaju ova svojstva.

**Poglavlje 28:  $k$  u  $k$ -struko unakrsnoj proverbi valjanosti** Istražuje ulogu parametra  $k$  u  $k$ -struko unakrsnoj proverbi valjanosti i pruža uvid u prednosti i mane izbora velike vrednosti za  $k$ .

**Poglavlje 29: Neslaganje između skupa za obuku i skupa za testiranje** Bavi se scenarijem u kom model ima bolje performanse na skupu podataka za testiranje, nego na skupu za obuku. Nudi strategije za otkrivanje i rešavanje neslaganja između skupova za obuku i testiranje, uvodeći koncept suparničke provere valjanosti.

**Poglavlje 30: Ograničeni označeni podaci** Predstavlja različite tehnike za poboljšanje performansi modela u situacijama kada su podaci ograničeni. Obrađuje označavanje podataka, uzorkovanje i paradigme, kao što su učenje prenosom znanja, aktivno učenje i multimodalno učenje.

## Onlajn resursi

Priložio sam dodatne materijale na GitHub platformi, sa primerima koda za određena poglavlja, da bih unapredio vaše iskustvo učenja (videti <https://github.com/rasbt/MachineLearning-QandAI-book>). Ovi materijali su osmišljeni kao praktična proširenja i detaljni pregledi tema obrađenih u knjizi. Možete ih koristiti uz svako poglavlje ili istraživati nakon čitanja, da biste učvrstili i proširili svoje znanje.

Bez daljeg odugovlačenja, zaronimo u materiju.



## Postanite član Kompjuter biblioteke

Kupovinom jedne naše knjige stekli ste pravo da postanete član Kompjuter biblioteke. Kao član možete da kupujete knjige u pretplati sa 40% popusta i učestvujete u akcijama kada ostvarujete popuste na sva naša izdanja. Potrebno je samo da se prijavite preko formulara na našem sajtu.

Link za prijavu: [kombib.rs/kblista.php](http://kombib.rs/kblista.php)

Skenirajte QR kod  
registrujte knjigu  
i osvojite nagradu



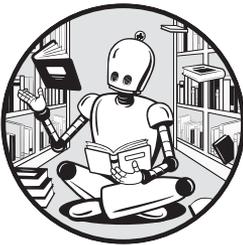
# Deo 1

**NEURONSKE MREŽE I  
DUBOKO UČENJE**



# 1

## UGRAĐENI VEKTORI, LATENTNI PROSTOR I REPREZENTACIJE



U DUBOKOM UČENJU ČESTO KORISTIMO TERMINE *UGRAĐENI VEKTORI*, *REPREZENTACIJE* I *LATENTNI PROSTOR*. ŠTA OVI KONCEPTI IMAJU ZAJEDNIČKO, A U ČEMU SE RAZLIKUJU?

Iako se ova tri termina često koriste naizmenično, možemo napraviti suptilne razlike između njih:

- Ugrađeni vektori su reprezentacije ulaznih podataka, gde su slični elementi blizu jedan drugome.
- Latentni vektori su međureprezentacije ulaznih podataka.
- Reprezentacije su kodirane verzije originalnog ulaza.

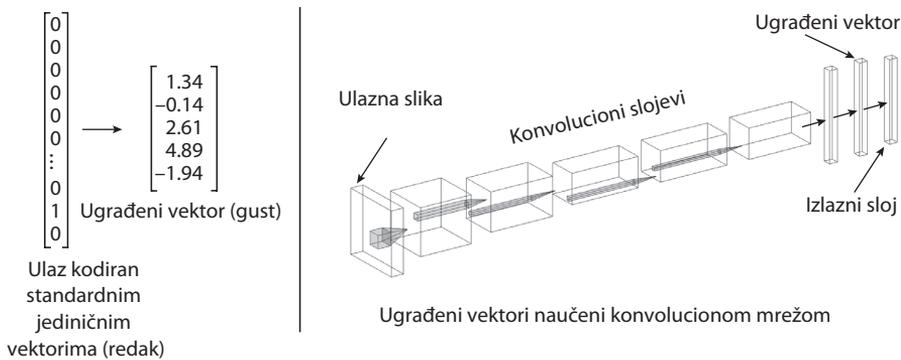
Naredni odeljci istražuju vezu između ugrađenih vektora, latentnih vektora i reprezentacija i kako svaki od njih funkcioniše u kodiranju informacija, u kontekstu mašinskog učenja.

### Ugrađeni vektori

Ugrađeni vektori, ili *ugrađivanja*, kodiraju relativno visokodimenzionalne podatke u relativno niskodimenzionalne vektore.

Možemo primeniti metode ugrađivanja da bismo kreirali neprekidan gusti (neretki) vektor iz (retkog) kodiranja standardnim jediničnim vektorima. *Kodiranje standardnim jediničnim vektorima* je metod za predstavljanje kvalitativnih podataka kao binarnih vektora, gde je svaka kategorija preslikana u vektor koji sadrži 1 na poziciji koja odgovara indeksu kategorije, a 0 na svim ostalim pozicijama. Ovo osigurava da su kvalitativne vrednosti predstavljene na način koji određeni algoritmi mašinskog učenja mogu da obrade. Na primer, ako imamo kvalitativnu promenljivu Boja sa tri kategorije, Crvena, Zelena i Plava, kodiranje standardnim jediničnim vektorima bi predstavljalo Crvenu kao  $[1, 0, 0]$ , Zelenu kao  $[0, 1, 0]$ , i Plavu kao  $[0, 0, 1]$ . Ove kvalitativne promenljive kodirane standardnim jediničnim vektorima mogu zatim biti preslikane u neprekidne ugrađene vektore pomoću naučene matrice težina ugrađenog sloja ili modula.

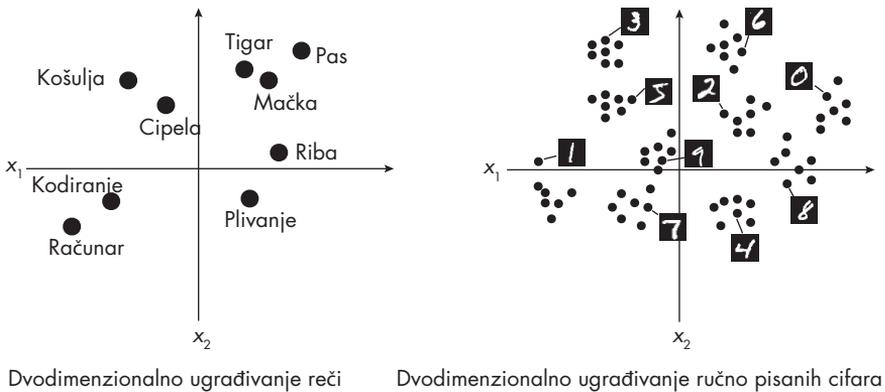
Takođe, metode ugrađivanja možemo koristiti za guste podatke, kao što su slike. Na primer, poslednji slojevi konvolucione neuronske mreže mogu proizvesti ugrađene vektore, kako je ilustrovano na slici 1-1.



**Slika 1-1:** Ugrađeni vektor ulaza (levo) i ugrađeni vektor iz neuronske mreže (desno)

Da bismo bili tehnički tačni, svi izlazi međuslojeva neuronske mreže mogu proizvesti ugrađene vektore. Zavisno od cilja obuke, izlazni sloj takođe može proizvesti korisne ugrađene vektore. Radi jednostavnosti, konvoluciona neuronska mreža na slici 1-1 povezuje pretposlednji sloj sa ugrađenim vektorom.

Ugrađeni vektori mogu imati veći ili manji broj dimenzija u odnosu na originalni ulaz. Na primer, pomoću metoda ugrađivanja za ekstremno izražavanje, možemo kodirati podatke u dvodimenzionalne guste i neprekidne reprezentacije u svrhu prikazivanja i klaster analize, kao što je ilustrovano na slici 1-2.



**Slika 1-2:** Preslikavanje reči (levo) i slika (desno) u dvodimenzionalni prostor karakteristika

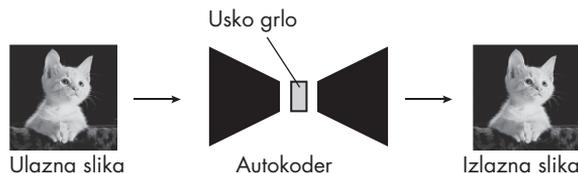
Osnovno svojstvo ugrađivanja je kodiranje *rastojanja* ili *sličnosti*. To znači da ugrađivanja zadržavaju semantiku podataka, tako da su slični ulazi blizu u prostoru ugrađenih vektora.

Za čitaoce zainteresovane za formalnije objašnjenje pomoću matematičke terminologije, ugrađivanje je injektivno preslikavanje koje čuva strukturu između prostora ulaza  $X$  i prostora ugrađivanja  $Y$ . To implicira da će slični ulazi biti smešteni na tačkama koje su blizu jedna drugoj u prostoru ugrađenih vektora, što se može posmatrati kao karakteristika ugrađenih vektora koja „čuva strukturu”.

## Latentni prostor

*Latentni prostor* se obično koristi kao sinonim za *prostor ugrađenih vektora*, prostor u koji su preslikani ugrađeni vektori.

Slični elementi se mogu pojaviti blizu u latentnom prostoru; međutim, to nije strogi zahtev. Opuštenije, možemo zamisliti latentni prostor kao bilo koji prostor karakteristika koji sadrži karakteristike, često kompresovane verzije originalnih ulaznih karakteristika. Ove karakteristike latentnog prostora mogu biti naučene od strane neuronske mreže, kao što je autokoder koji rekonstruiše ulazne slike, kako je prikazano na slici 1-3.



**Slika 1-3:** Autokoder rekonstruiše ulaznu sliku

Usko grlo na slici 1-3 predstavlja mali, međusloj neuronske mreže koji kodira ili preslikava ulaznu sliku u reprezentaciju niže dimenzije. Možemo zamisliti ciljni prostor ovog preslikavanja kao latentni prostor. Cilj obuke autokodera je da rekonstruiše ulazne slike, odnosno da minimizira rastojanja između ulaznih i izlaznih slika. Da bi optimizovao cilj obuke, autokoder može naučiti da postavi kodirane karakteristike sličnih ulaza (na primer, slike mačaka) blizu jedan drugom u latentnom prostoru, čime se stvaraju korisni ugrađeni vektori, gde su slični ulazi blizu u (latentnom) prostoru ugrađenih vektora.

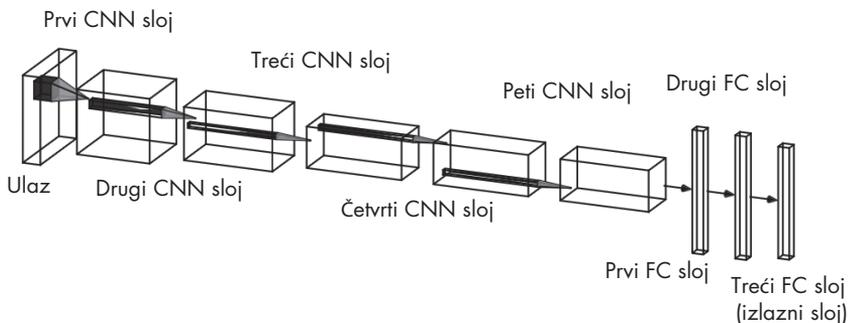
## Reprezentacija

*Reprezentacija* je kodirana, obično međuforna ulaza. Na primer, ugrađeni vektor ili vektor u latentnom prostoru je reprezentacija ulaza, kao što je ranije pomenuto. Međutim, reprezentacije mogu biti proizvedene i jednostavnijim postupcima. Na primer, vektore kodirane standardnim jediničnim vektorima smatramo reprezentacijama ulaza.

Ključna ideja je da reprezentacija zadržava neke bitne karakteristike ili osobine originalnih podataka da bi ih učinila korisnim za dalju analizu ili obradu.

## Vežbe

- 1-1. Pretpostavimo da obučavamo konvolucionu mrežu sa pet konvolucionih slojeva, praćenih sa tri potpuno povezana (FC) sloja, slično kao AlexNet neuronska mreža (<https://en.wikipedia.org/wiki/AlexNet>), kao što je ilustrovano na slici 1-4.



**Slika 1-4:** Ilustracija neuronske mreže AlexNet

Ove potpuno povezane slojeve možemo posmatrati kao dva skrivena sloja i jedan izlazni sloj u višeslojnom perceptronu. Koji slojevi neuronske mreže mogu biti iskorišćeni za proizvodnju korisnih ugrađivanja? Zainteresovani čitaoci mogu pronaći više detalja o arhitekturi i implementaciji AlexNet neuronske mreže u originalnoj publikaciji autora Aleksa Križevskog, Ilje Suckevera i Džefrija Hintona.

- 1-2. Navedite neke vrste reprezentacija ulaza koje nisu ugrađeni vektori.

---

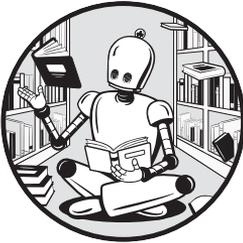
## Literatura

- Originalni rad koji opisuje arhitekturu i implementaciju AlexNet neuronske mreže: Alex Krizhevsky, Ilya Sutskever, and Geoffrey Hinton, „ImageNet Classification with Deep Convolutional Neural Networks” (2012), <https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks>.



# 2

## SAMONADGLEDANO UČENJE



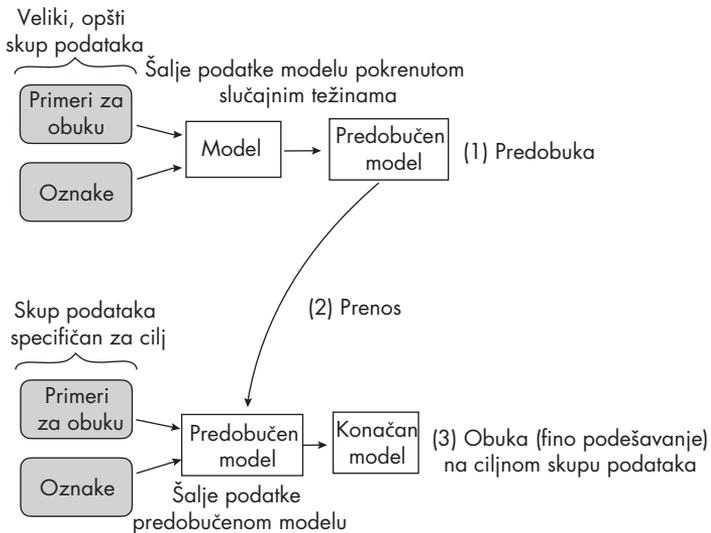
ŠTA JE SAMONADGLEDANO UČENJE, KADA JE KORISNO I KOJI SU GLAVNI PRISTUPI ZA NJEGOVO SPROVOĐENJE?

*Samonadgledano učenje* je postupak prethodne obuke koji omogućava neuronskim mrežama da iskoriste velike skupove neobeženih podataka na nadgledan način. Ovo poglavlje poredi samonadgledano učenje i učenje prenosom znanja, srodnim metodom za prethodno obučavanje neuronskih mreža, i razmatra praktične primene samonadgledanog učenja. Na kraju, ističe glavne kategorije samonadgledanog učenja.

### **Samonadgledano učenje naspram učenja prenosom znanja**

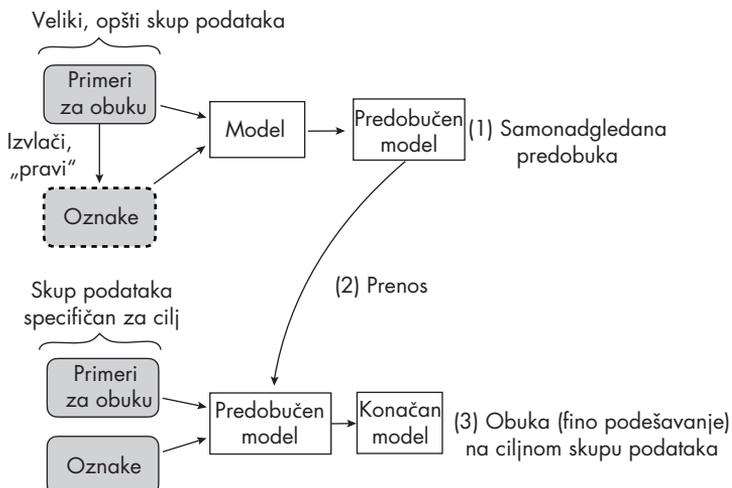
Samonadgledano učenje je povezano sa učenjem prenosom znanja, tehnikom u kojoj se model koji je prethodno obučen za jedan zadatak ponovo koristi kao početna tačka za model koji obavlja drugi zadatak. Na primer, pretpostavimo da želimo da obučimo klasifikator slika da klasifikuje vrste ptica. U učenju prenosom znanja, prethodno bismo obučavali konvolucionu neuronsku mrežu na ImageNet skupu podataka, velikom skupu označenih slika sa mnogo različitih kategorija, uključujući različite objekte i životinje. Nakon prethodne obuke na opštem ImageNet skupu podataka, uzeli bismo taj prethodno obučeni model i obučavali ga na manjem, specifičnijem ciljnom skupu podataka koji sadrži vrste ptica koje nas zanimaju. (Uglavnom,

potrebno je samo promeniti izlazni sloj specifičan za klase, ali inače možemo preuzeti prethodno obučenu mrežu onakvu kakva jeste). Slika 2-1 ilustruje proces učenja prenosom znanja.



**Slika 2-1:** Prethodna obuka konvencionalnim učenjem prenosom znanja

Samonadgledano učenje je alternativan pristup učenju prenosom znanja u kojem se model prethodno obučava ne na obeleženim podacima, već na *neobebeženim* podacima. Razmatramo skup neobebeženih podataka za koji nemamo informacije o oznakama, a zatim pronalazimo način da dobijemo oznake iz strukture skupa podataka, da bismo formulisali zadatak predviđanja za neuronsku mrežu, kao što je ilustrovano na slici 2-2. Ove zadatke samonadgledane obuke takođe nazivamo *nadzirani zadaci*.



**Slika 2-2:** Predobuka sa samonadgledanim učenjem

Glavna razlika između učenja prenosom znanja i samonadgledanog učenja je u tome kako dobijamo oznake tokom koraka 1, na slikama 2-1 i 2-2. U učenju prenosom znanja, pretpostavljamo da su oznake dostupne zajedno sa skupom podataka; obično ih kreiraju ljudi. U samonadgledanom učenju, oznake se mogu direktno izvesti iz primera za obuku.

Zadatak samonadgledanog učenja može biti predviđanje reči koja nedostaje, u kontekstu obrade prirodnog jezika. Na primer, za datu rečenicu „Napolju je lepo i sunčano”, možemo zamaskirati reč *sunčano*, proslediti mreži ulaz „Napolju je lepo i [MASKA]” i tražiti od mreže da pogodi reč koja nedostaje, na mestu „[MASKA]”. Slično tome, u kontekstu računarskog prepoznavanja slika, možemo ukloniti delove slike i pustiti neuronsku mrežu da popuni praznine. Ovo su samo dva primera zadatka samonadgledanog učenja; postoji mnogo više metoda i paradigmi za ovu vrstu učenja.

Ukratko, možemo razmišljati o samonadgledanom učenju na nadziranom zadatku kao o *reprezentativnom učenju*. Možemo uzeti prethodno obučeni model i fino ga podesiti na ciljnom zadatku (takođe poznatom kao *sledeći zadatak*).

## Korišćenje neoznačenih podataka

Velike arhitekture neuronskih mreža zahtevaju velike količine označenih podataka da bi dobro funkcionisale i generalizovale. Međutim, za probleme iz mnogih oblasti nemamo pristup velikim skupovima označenih podataka. Sa samonadgledanim učenjem, možemo iskoristiti neobeležene podatke. Stoga je samonadgledano učenje verovatno korisno kada radimo sa velikim neuronskim mrežama i sa ograničenom količinom označenih podataka za obuku.

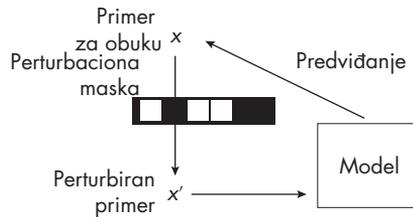
Arhitekture zasnovane na transformatorima, koje čine osnovu velikih jezičkih modela sa vizuelnim transformatorima, poznato je da zahtevaju samonadgledano učenje za prethodnu obuku da bi dobro funkcionisale.

Za male modele neuronskih mreža, poput višeslojnih perceptrona sa dva ili tri sloja, samonadgledano učenje obično se ne smatra ni korisnim ni neophodnim.

Slično tome, samonadgledano učenje nije korisno ni u tradicionalnom mašinskom učenju sa neparаметarskim modelima, kao što su slučajne šume zasnovane na stablima ili gradijentno poboljšanje. Konvencionalne metode zasnovane na stablima nemaju fiksnu strukturu parametara (za razliku od matrica težina, na primer). Stoga, konvencionalne metode zasnovane na stablima nisu sposobne za učenje prenosom znanja i nisu kompatibilne sa samonadgledanim učenjem.

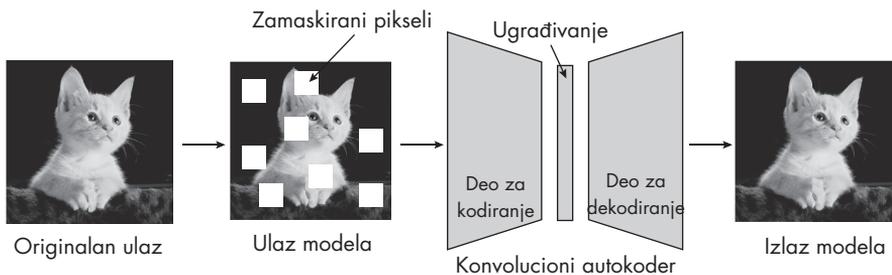
## Samopredviđanje i kontrastno samonadgledano učenje

Postoje dve glavne kategorije samonadgledanog učenja: samopredviđanje i kontrastno samonadgledano učenje. U *samopredviđanju*, prikazanom na slici 2-3, obično menjamo ili skrivamo delove ulaza i obučavamo model da rekonstruiše originalne ulaze, na primer, pomoću perturbacione maske koja zamagluje određene piksele na slici.



**Slika 2-3:** Samopredviđanje nakon primene perturbacione maske

Klasičan primer je autokoder za uklanjanje šuma, koji uči da ukloni šum sa ulazne slike. Kao alternativu, razmotrite autokoder sa maskom, koji rekonstruiše delove slike koji nedostaju, kao što je prikazano na slici 2-4.



**Slika 2-4:** Autokoder sa maskom rekonstruiše maskiranu sliku

Metode samopredviđanja sa (zamaskiranim) ulazima koji nedostaju, takođe se često koriste u kontekstu obrade prirodnog jezika. Mnogi generativni veliki jezički modeli, kao što je GPT, obučavaju se na nadziranom zadatku predviđanja sledeće reči (GPT će biti detaljnije razmotren u poglavljima 14 i 17). Ovde šaljem tekstualne fragmente mreži koja mora da predvidi sledeću reč u nizu (kao što ćemo dalje razmotriti u poglavlju 17).

U *kontrastnom samonadgledanom učenju*, obučavamo neuronsku mrežu da nauči prostor ugrađenih vektora, gde su slični ulazi blizu jedni drugima, a različiti ulazi udaljeni jedni od drugih. Drugim rečima, obučavamo mrežu da proizvodi ugrađene vektore koji minimiziraju rastojanje između sličnih ulaznih podataka za obuku i maksimiziraju rastojanje između različitih primera za obuku.

Hajde da razmotrimo kontrastno učenje pomoću konkretnih ulaznih primera. Pretpostavimo da imamo skup podataka koji se sastoji od slučajnih slika životinja. Prvo, izvlačimo slučajnu sliku mačke (mreža ne zna oznaku, jer pretpostavljamo da je reč o skupu neoznačenih podataka). Zatim, uvećavamo, oštećujemo ili zamagljujemo ovu sliku mačke, na primer, dodavanjem sloja slučajnog šuma i različitim isecanjima, kao što je prikazano na slici 2-5.

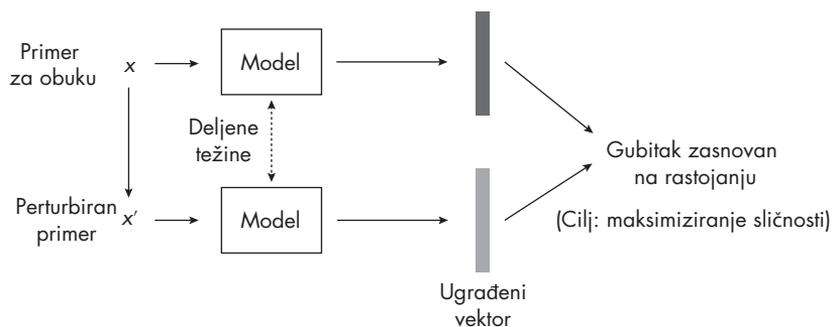


**Slika 2-5:** Parovi slika specifični za kontrastno učenje

Perturbirana slika mačke na ovoj slici i dalje prikazuje istu mačku, pa želimo da mreža proizvede sličan ugrađen vektor. Takođe, razmatramo slučajno izabranu sliku iz skupa za obuku (na primer, sliku slona, ali opet, mreža ne zna oznaku).

Za par mačka-slona, želimo da mreža proizvede različite ugrađene vektore. Na taj način, implicitno prisiljavamo mrežu da uhvati osnovni sadržaj slike a da u određenoj meri bude ravnodušna prema malim razlikama i šumu. Na primer, najjednostavniji oblik kontrastnog gubitka je  $L_2$ -norma (Euklidovo rastojanje) između ugrađenih vektora koje proizvodi model  $M(\cdot)$ . Recimo da ažuriramo težine modela da bismo smanjili rastojanje  $\|M(\text{mačka}) - M(\text{mačka}')\|_2$  i uvećali rastojanje  $\|M(\text{mačka}) - M(\text{slon})\|_2$ .

Slika 2-6 prikazuje centralni koncept kontrastnog učenja za scenario perturbirane slike. Model je prikazan dva puta, što je poznato kao postavljanje *sijamske mreže*. U suštini, isti model se koristi u dva slučaja: prvo, da generiše ugrađivanje za originalan primer za obuku, i drugo, da proizvede ugrađivanje za perturbiranu verziju primera.



**Slika 2-6:** Kontrastno učenje

Ovaj primer naglašava osnovnu ideju kontrastnog učenja, ali postoji mnogo podvarijanti. Uopšteno posmatrano, ove podvarijante možemo podeliti na metode *uzoračke kontrastivnosti* i metode kontrastiranja *dimenzija*. Primer slona i mačke na slici 2-6 ilustruje metod uzoračke kontrastivnosti, gde se fokusiramo na učenje ugrađivanja da bismo minimizirali i maksimizirali rastojanja između parova za obuku. S druge strane, u pristupima kontrastiranja dimenzija, fokusiramo se na to da samo određene promenljive u ugrađenim reprezentacijama sličnih parova za obuku budu blizu jedna drugoj, dok se maksimizira rastojanje ostalih.

## Vežbe

- 2-1.      Kako bismo primenili samonadgledano učenje na video podatke?
- 2-2.      Da li se samonadgledano učenje može koristiti za tabelirane podatke predstavljene u vidu redova i kolona? Ako može, koji bi bio naš pristup?

## Literatura

- Za više informacija o skupu podataka ImageNet: <https://en.wikipedia.org/wiki/ImageNet>.
- Primer kontrastnog metoda samonadgledanog učenja: Ting Chen et al., „A Simple Framework for Contrastive Learning of Visual Representations” (2020), <https://arxiv.org/abs/2002.05709>.
- Primer metoda kontrastiranja dimenzija: Adrien Bardes, Jean Ponce, and Yann LeCun, „VICRegL: Self-Supervised Learning of Local Visual Features” (2022), <https://arxiv.org/abs/2210.01571>.
- Ako planirate da primenite samonadgledano učenje u praksi: Randall Balestriero et al., „A Cookbook of Self-Supervised Learning” (2023), <https://arxiv.org/abs/2304.12210>.
- Rad koji predlaže metod učenja prenosom znanja i samonadgledanog učenja za relativno male višeslojne perceptrone na skupovima tabeliranih podataka: Dara Bahri et al., „SCARF: Self-Supervised Contrastive Learning Using Random Feature Corruption” (2021), <https://arxiv.org/abs/2106.15147>.
- Drugi rad koji predlaže taj metod: Roman Levin et al., „Transfer Learning with Deep Tabular Models” (2022), <https://arxiv.org/abs/2206.15306>.