



Kompetenčni
center za
umetno
inteligenco

Slovenian
National
AI Competence
Centre



Uvod v strojno učenje: Kako iz podatkov nastanejo napovedi

Miran Meža, Marko Meža, Andraž Sivec
Delavnica se izvaja v prostoru LUCAMI (klet nove stavbe)



REPUBLIKA SLOVENIJA
MINISTRSTVO ZA NOTRANJE ZADEVE
IN JAVNO UPRAVO



REPUBLIKA SLOVENIJA
MINISTRSTVO ZA IZOBRAŽEVANJE, ZNANOST
IN MLADINO



REPUBLIKA SLOVENIJA
MINISTRSTVO ZA GOSPODARSTVO
DELO IN ŠPORT



REPUBLIKA SLOVENIJA
MINISTRSTVO ZA OBRAMBO





Nevronske mreže




UNIVERZA
V LJUBLJANI

FE

Fakulteta
za elektrotehniko



Univerzalni algoritem učenja - hipoteza



Avditorni korteks se nauči videti



MIT research hearing can le

April 19, 2000

CAMBRIDGE, Mass. – A Massachusetts
20 issue of *Nature* that when an animal
auditory cortex, this part of the brain d

nature > articles > article

nature
International journal of science

Article | Published: 20 April 2000

Induction of visual orientation modules in auditory cortex

Jitendra Sharma, Alessandra Angelucci & Mriganka Sur 

Nature **404**, 841–847 (20 April 2000) | [Download Citation](#) 

Abstract

Modules of neurons sharing a common property are a basic organizational feature of mammalian sensory cortex. Primary visual cortex (V1) is characterized by orientation modules—groups of cells that share a preferred stimulus orientation—which are organized into a highly ordered orientation map. Here we show that in ferrets in which retinal projections are routed into the auditory pathway, visually responsive neurons in ‘rewired’ primary auditory cortex are also organized into orientation modules. The orientation tuning of neurons



FE


UNIVERZA
V LJUBLJANI

Fakulteta
za elektrotehniko



Nevronske mreže

od umetnega nevrona do globokih modelov in LLM






Zakaj nevrnske mreže?


Ko povezava med značilkami in izhodom ni več preprosta

Preprosti modeli



regresija • logistična regresija

Nevronske mreže



učenje nelinearnih povezav

Kje so uporabne?


-  **slike** računalniški vid
-  **zvok** prepoznavanje govora
-  **besedilo** jezikovni modeli
-  **signali** napovedovanje in klasifikacija

Ključna ideja: model se iz podatkov nauči notranjih predstavitev, ki jih ni treba ročno zapisati.



En umetni nevron

Najmanjša gradna enota nevronske mreže



značilke

Uteži

določajo, kako močno posamezen vhod vpliva na izhod.

Aktivacija

vnese nelinearnost – zato lahko mreža modelira kompleksne povezave.


Učenje

v praksi predvsem pomeni prilagajanje uteži in pristranskosti.



Od nevrona do mreže

Plasti nevronov zaporedno preoblikujejo informacije




Pri napovedi podatki tečejo od vhoda proti izhodu – temu rečemo vnaprejšnja propagacija (forward pass).



Kako se mreža uči?

Ponavljanje: napoved → napaka → popravek uteži

ponavljamo na mnogih vzorcih




Matematika v ozadju: povratno razširjanje napake (backpropagation) in optimizacija.



Globoke nevronske mreže: primer ResNet


»Globoko« pomeni veliko zaporednih plasti – vendar več plasti ni samodejno boljše

Hierarhija značilk



Pri slikah se zgodnje plasti pogosto odzivajo na preproste vzorce, kasnejše pa na kompleksnejše strukture.

ResNet – residualna povezava



Izhod bloka: $F(x) + x$

Residualne povezave so omogočile učinkovito učenje zelo globokih mrež. ResNet-50 je primer mreže z okoli 50 plastmi.



FE

UNIVERZA
V LJUBLJANI

Fakulteta
za elektrotehniko



Od globokih mrež do LLM

Veliki jezikovni modeli so prav tako nevronske mreže – le z drugačno arhitekturo in ogromnim številom parametrov



Ista osnovna ideja

uteži se naučijo iz podatkov

Druga arhitektura

Transformer uporablja mehanizem attention

Drugačen obseg

veliko plasti, podatkov in parametrov

Povezava z današnjo temo: tudi pri LLM-u so jedro naučene uteži, plasti in nelinearne transformacije – le arhitektura je bistveno naprednejša.





Mini demonstracija: Google Teachable Machine

V nekaj minutah zgradimo slikovni klasifikator brez pisanja kode

1 Zberemo primere

npr. pest / odprta dlan
/ ozadje

2 Naučimo model

nekaj deset vzorcev na
razred

3 Preizkusimo

kamera pokaže
verjetnosti razredov

Kaj se dogaja v ozadju?

Slikovni model uporablja že
naučene značilke (MobileNet)
in na vrhu nauči našo novo
klasifikacijo – primer
transfernega učenja.



teachablemachine.withgoogle.com

Demonstracija: 3 razredi gest → trening → test na osebi iz publike.

Opazujmo: vpliv števila in raznolikosti učnih primerov na zanesljivost napovedi.



Praktični primer: razvrščanje igralcev

Iz performančnih podatkov želimo napovedati vrednost igralca za klub

Vhodne značilke

točke / uspešnost


minute / nastopi

drugi performančni
kazalniki

...

Player_Name = id

Nevronska mreža



Ciljni razred: Team_Value

Role Player

Contributor

Franchise Player

Superstar

Mreža se nauči preslikavo: značilke → eden od štirih razredov.