

Usporedba metoda za učenje neuronskih mreža za igru zmija

ZAVRŠNI RAD br. 489

Pristupnik: Leo Goršić (0036523443)

Mentor: Marko Đurasević

Sadržaj

- Motivacija
- Cilj rada
- Opis problema
- Metodika testiranja i vrednovanja
- Prikaz rezultata
- Zaključak

Motivacija

- Jednostavna i vrlo popularna igra
- Pogodna za implementaciju AI agenta
- Optimalan izbor parametara?
→ Otvoreno pitanje

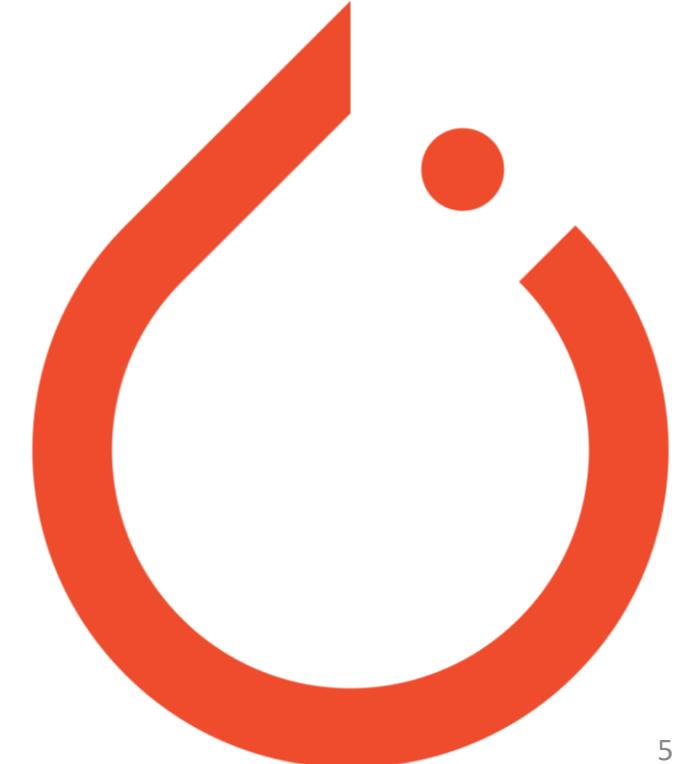


Cilj rada

- Otkriti optimalan izbor arhitekture neuronske mreže
- Otkriti optimalne parametre za neuronsku mrežu
- Otkriti optimalan način učenja neuronske mreže

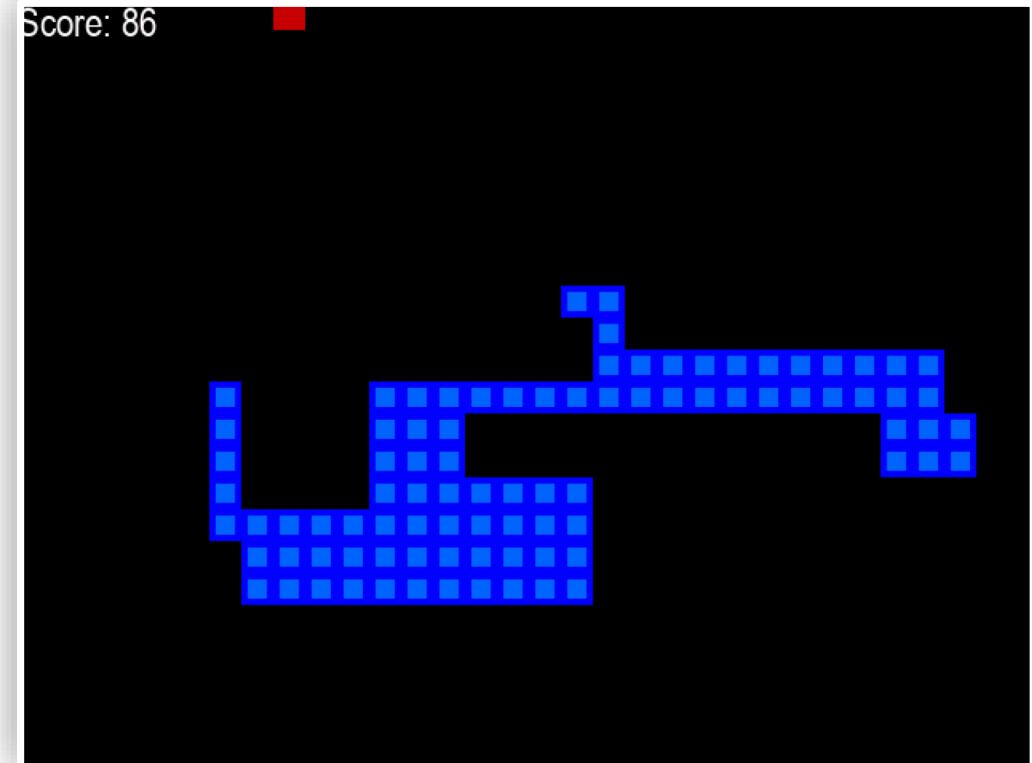
Opis problema

- Implementacija u Pythonu pomoću Pygame i Pytorch biblioteka
- Pogled (View)
- Model
- Nadglednik (Controller)



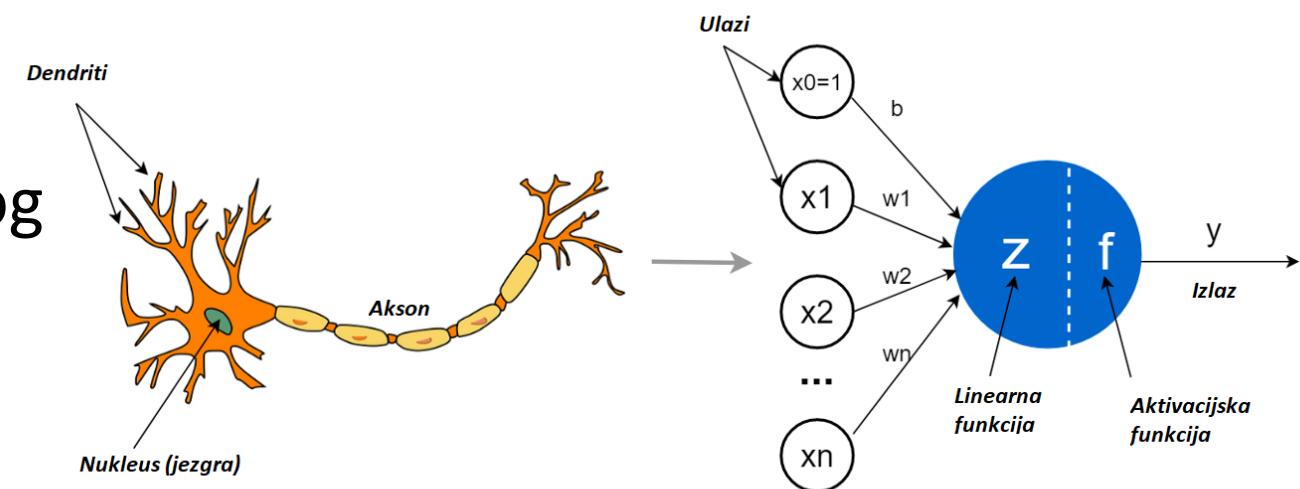
Opis problema

- Implementiran deterministički algoritam
- Najkraći **siguran** put
- Solidni rezultati
- „Učitelj” za neuronsku mrežu (nadzirano učenje)
- Boxing!



Umjetna neuronska mreža

- Skup međusobno povezanih jednostavnih procesnih elemenata
- Analogija biološkog i umjetnog neurona



Model neuronske mreže

- Broj neurona u ulaznom i izlaznom sloju je konstantan!
- Variramo:
 - Skrivenе slojeve (broj slojeva i neurona)
 - Kriterij za izračun gubitka
 - Optimizator
 - Aktivacijska funkcija

Model neuronske mreže

Ulagni vektor:

- [0] ○ Opasnost ispred
- [1] ○ Opasnost zdesna
- [0] ○ Opasnost slijeva
- [1] ○ Smjer kretanja lijevo
- [0] ○ Smjer kretanja desno
- [0] ○ Smjer kretanja gore
- [0] ○ Smjer kretanja dolje
- [0] ○ Lokacija hrane po koordinati x manja od koordinate glave
- [1] ○ Lokacija hrane po koordinati x veća od koordinate glave
- [0] ○ Lokacija hrane po koordinati y manja od koordinate glave
- [1] ○ Lokacija hrane po koordinati y veća od koordinate glave

Model neuronske mreže

Izlazni vektor:

- Idi ravno (zadrži smjer) [1 0 0]
- Skreni desno [0 1 0]
- Skreni lijevo [0 0 1]

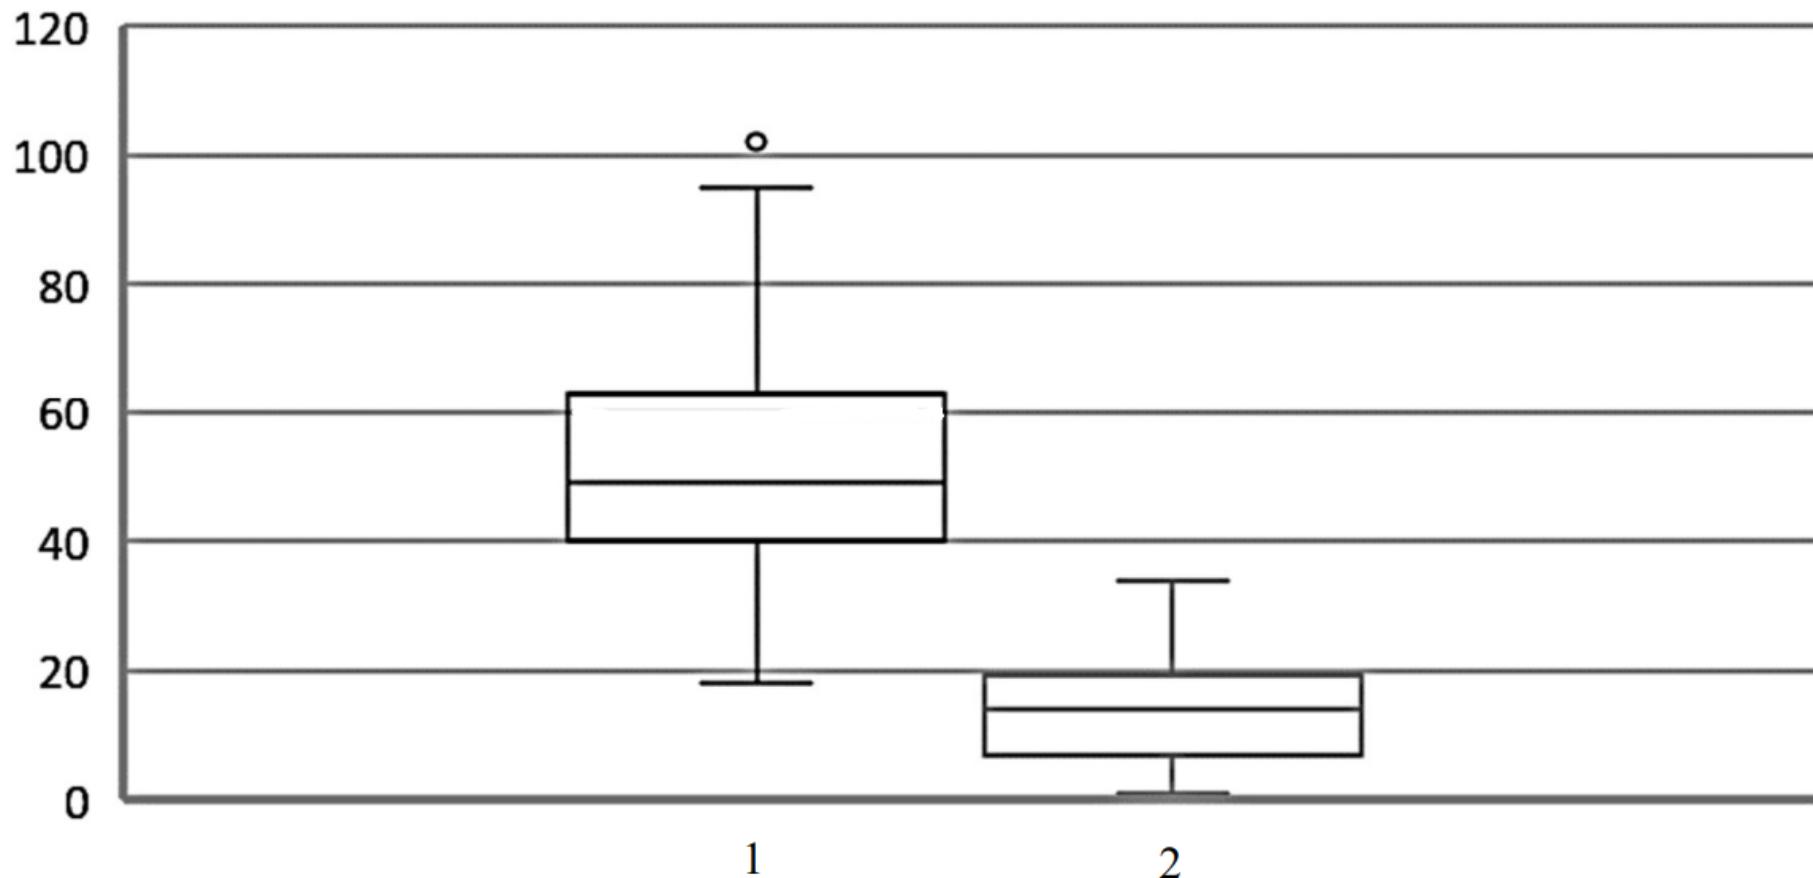
Metodika testiranja i vrednovanja rezultata

- 10 minuta treniranja → rezultat se ignorira
- Prikuplja se uzorak od 100 igara → rezultat se bilježi u csv datoteku
- Podaci koji se prikupljaju:
 - Game Number
 - Score
 - Max Score
 - Deterministic Flag
- Kriterij optimiranja: broj pojedene hrane - score (prosjek rezultata prikupljenog uzorka)

Prikaz rezultata

- Inicijalna postavka neuronske mreže:
- $11 \times 256 \times 40 \times 3$ (u tekstu: „inicijalna postavka”)
- ReLU (zglobnica)
- ADAM
- L1Loss

Prikaz rezultata



Slika 4.2: Prikaz box plot dijagrama rezultata:

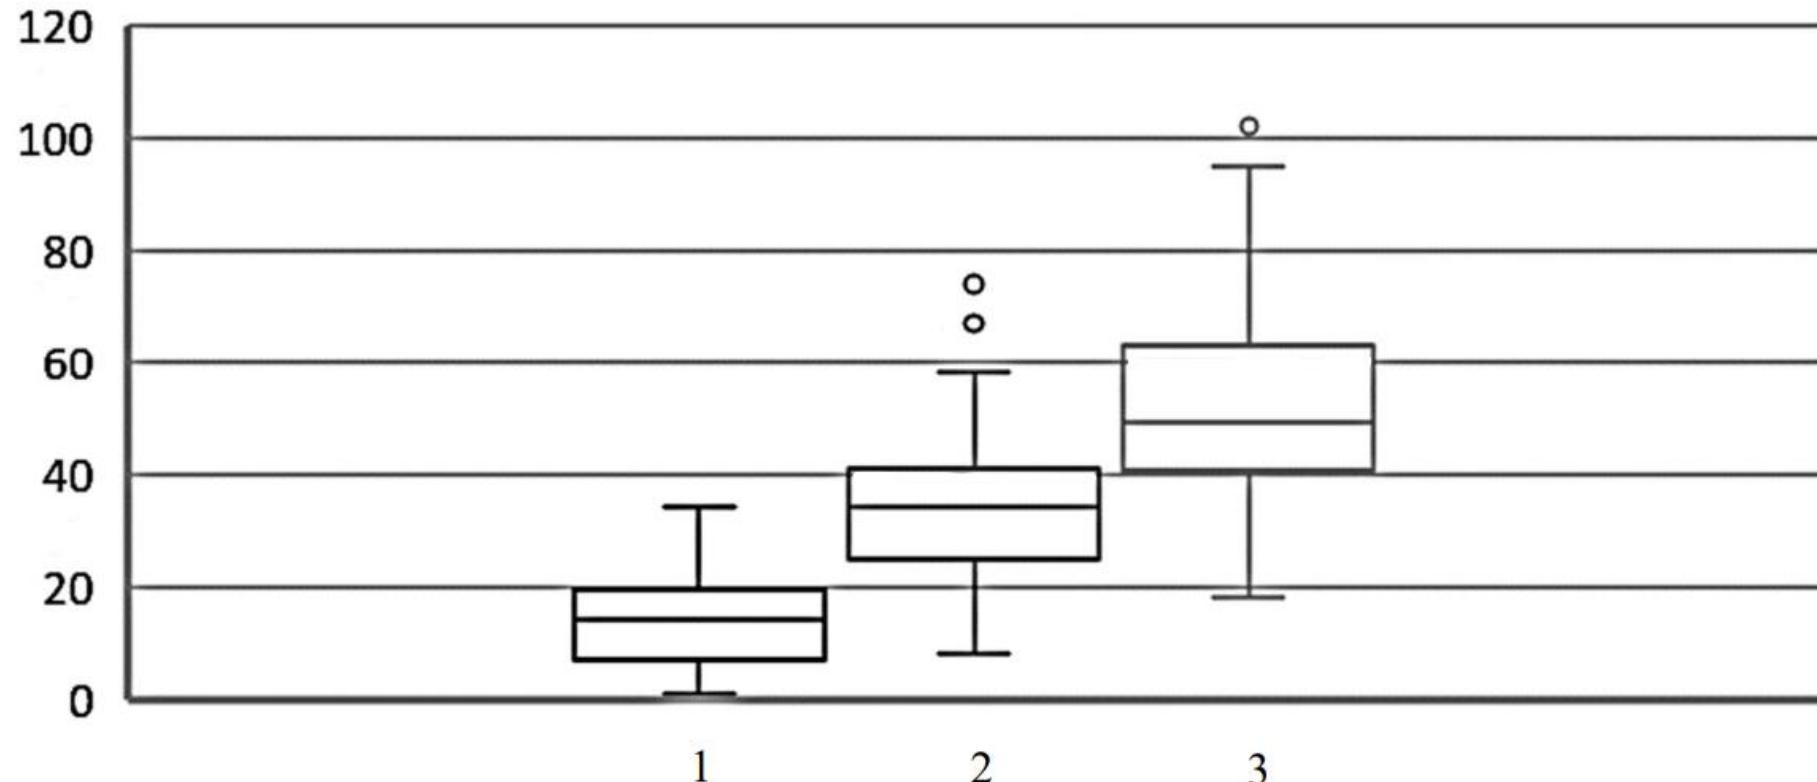
1: deterministički algoritam

2: neuronska mreža [Inicijalna postavka]

Prikaz rezultata

- Zmija se ubija na trivijalne načine!
- Uvodimo ograničenje na sigurne poteze.
- Rezultati bi trebali biti na razini determinističkog algoritma...
- Rezultati su bolji ali nisu na razini determinističkog!

Prikaz rezultata



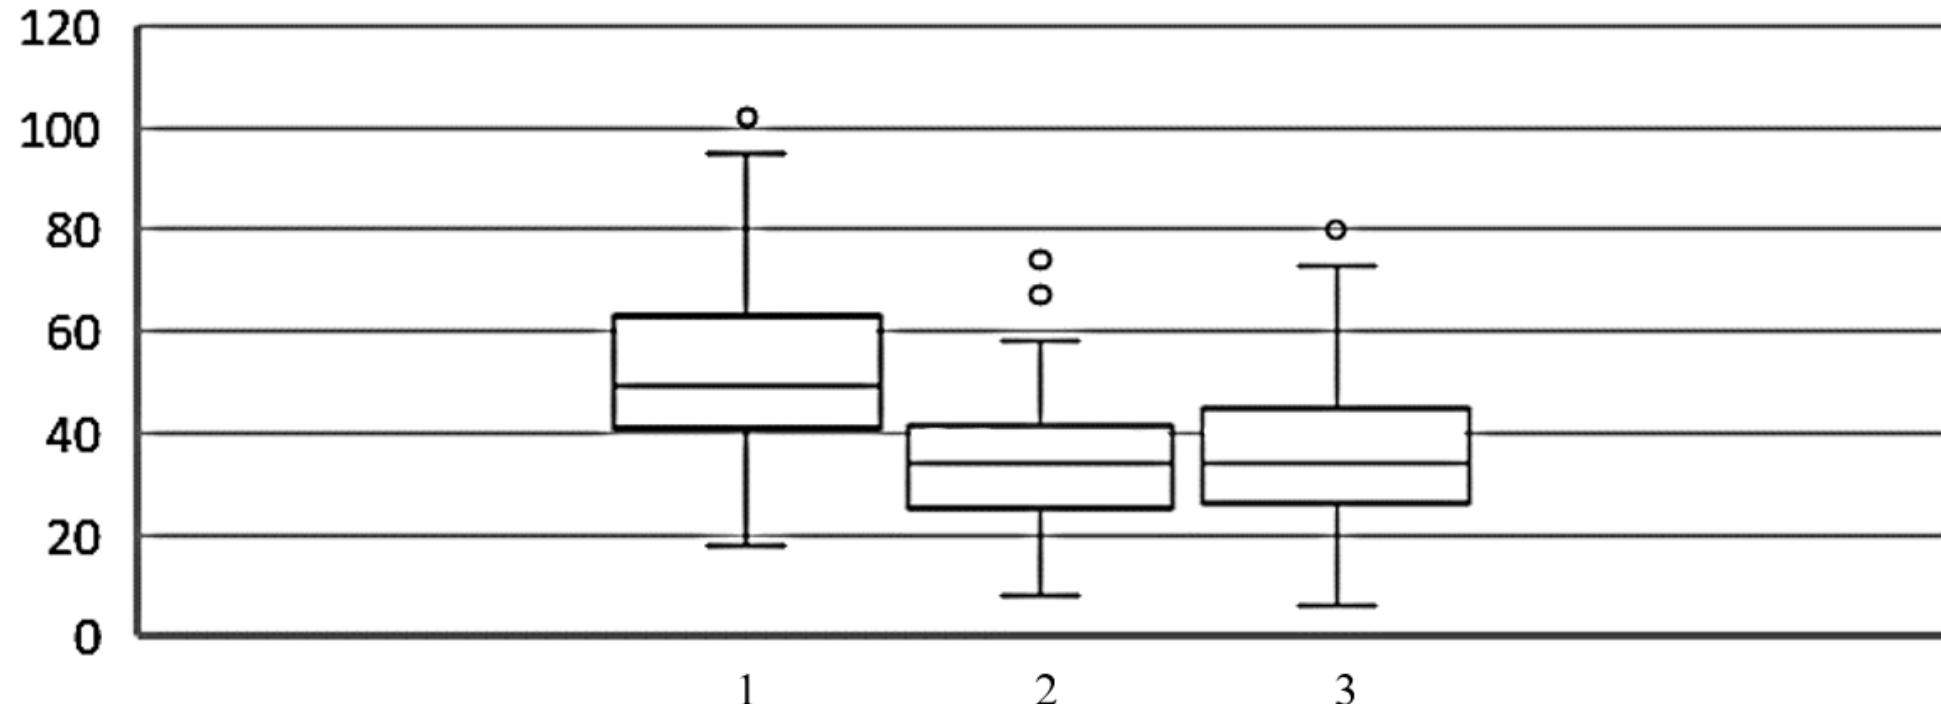
Slika 4.3: Prikaz box plot dijagrama rezultata:

- 1: neuronska mreža [Inicijalna postavka]
- 2: potpomognuta neuronska mreža
- 3: deterministički algoritam

Prikaz rezultata

- I dalje ograničenje na sigurne poteze...
- Adam zamijenjen sa RMSProp
- Aktivacijska funkcija i kriterij gubitka isti (ReLU, aps. pogreška)
- Postignuto malo poboljšanje!

Prikaz rezultata

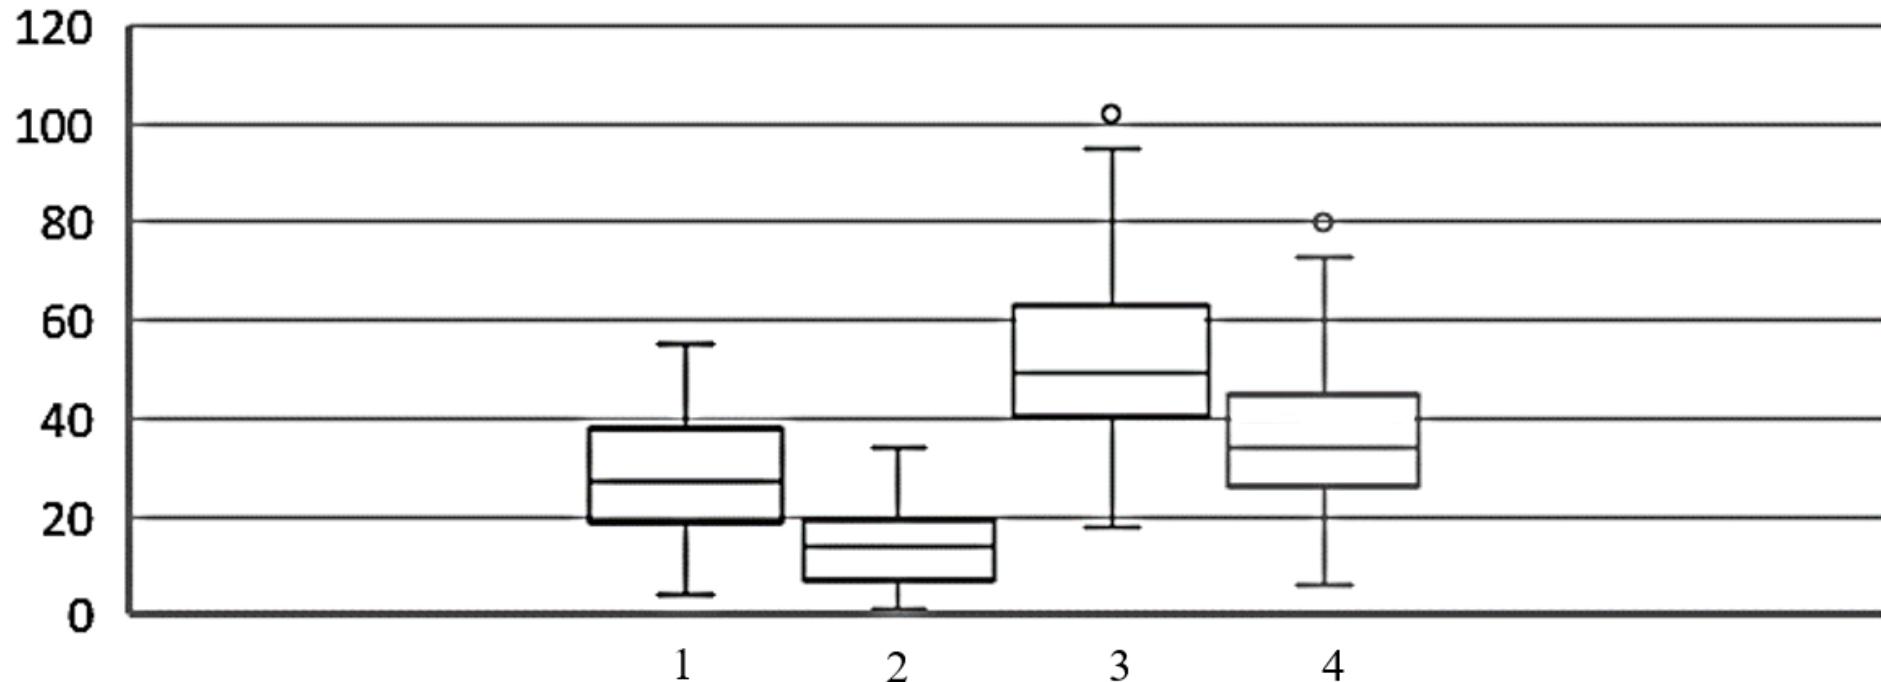


Slika 4.4: Prikaz box plot dijagrama rezultata:
1: deterministički algoritam
2: Potpomognuta neuronska mreža, Adam optimizator
3: Potpomognuta neuronska mreža, RmsProp optimizator

Prikaz rezultata

- Uklanjamo ograničenje na sigurne poteze.
- Umjesto L1Loss uvodi se MSE (srednja kvadratna pogreška)
- U drugom skivenom sloju sigmoidalna prijenosna funkcija
- Drugi skriveni sloj povećan za 50 neurona
- Struktura mreže je: 11x256x90x3 (dalje u tekstu: „**složena neuronska mreža**“)
- Nismo postigli očekivano poboljšanje...

Prikaz rezultata



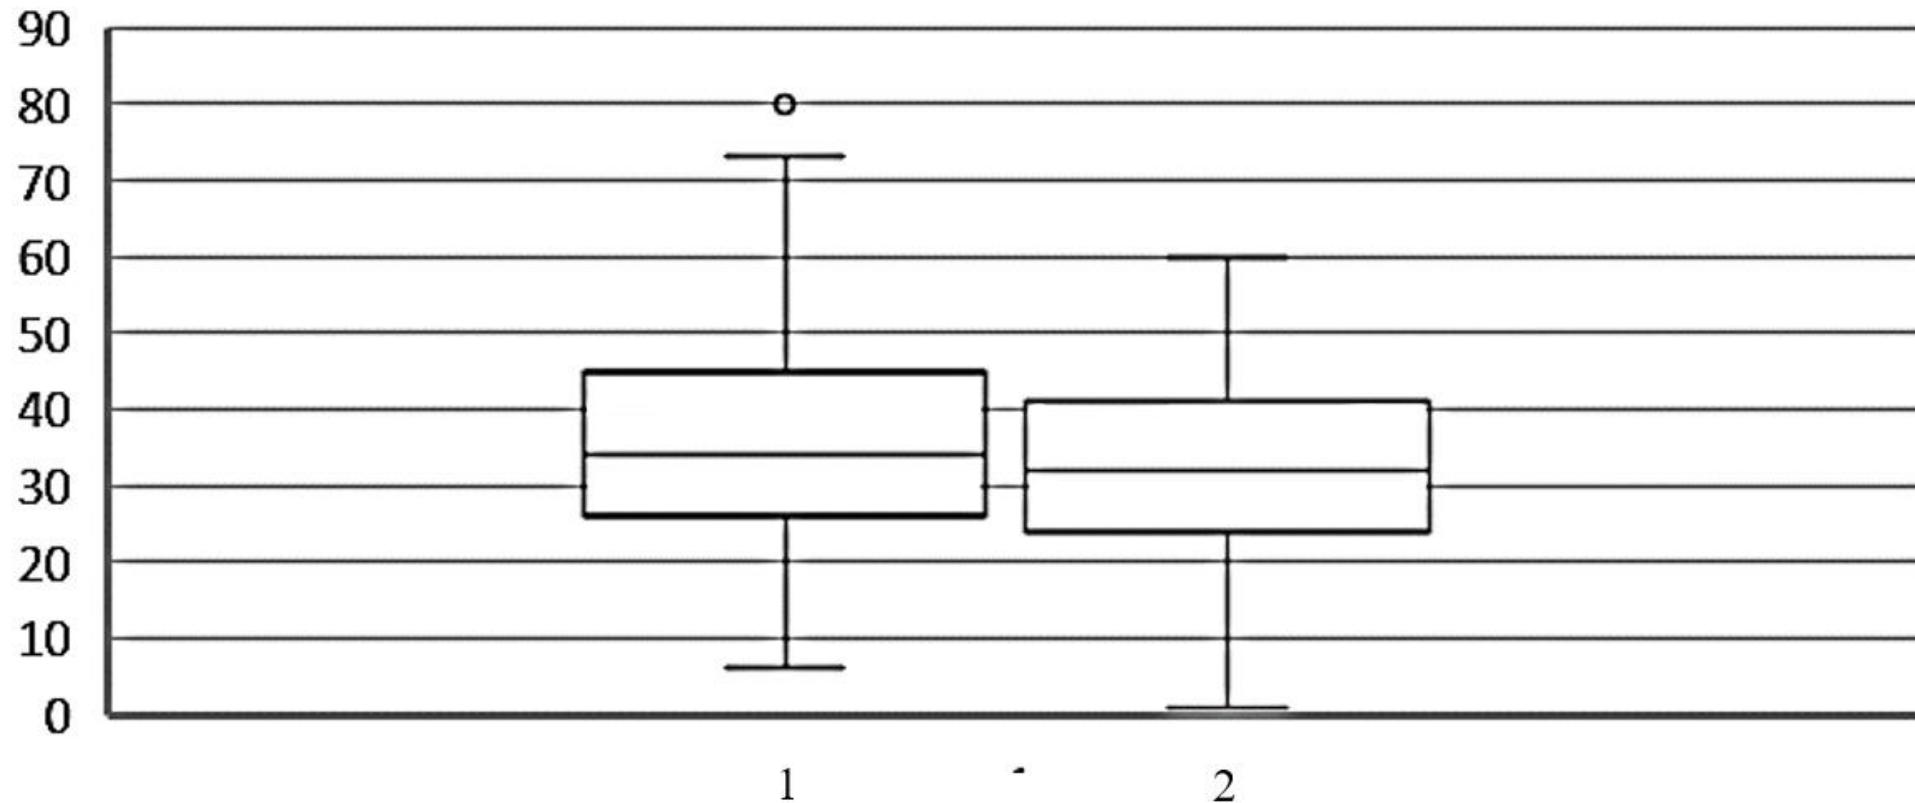
Slika 4.5: Box plot dijagram rezultata neuronskih mreža:

- 1: RmsProp optimizator, arhitektura 11x256x90x3, MSE kriterij gubitka [**Složena neuronska mreža**]
- 2: Adam optimizator, arhitektura 11x256x40x3, L1 kriterij gubitka [**Inicijalna postavka**]
- 3: Deterministički algoritam (nema neuronske mreže)
- 4: Potpomognuta neuronska mreža, RmsProp optimizator, arhitektura 11x256x40x3, L1 kriterij gubitka [**Potpomognuta neuronska mreža**]

Prikaz rezultata

- Suprotni pristup → želimo mrežu pojednostavniti!
- Uklanja se drugi skriveni sloj.
- Arhitektura: $11 \times 256 \times 3$ (dalje u tekstu „**Pojednostavljena neuronska mreža**“)
- RMSProp optimizator, ReLU aktivacijska funkcija, MSE kriterij gubitka
- Značajno poboljšanje!
- Rezultati usporedivi s rezultatima neuronske mreže koja ima ograničenje na sigurne poteze.

Prikaz rezultata



Slika 4.6: Box plot prikaz rezultata:

- 1: Potpomognuta neuronska mreža, RmsProp optimizator, arhitektura 11x256x40x3 ,L1Loss kriterij gubitka [Potpomognuta neuronska mreža]
2: Obična neuronska mreža, arhitektura 11x256x3, RmsProp optimizator, MSE kriterij gubitka [Pojednostavljena neuronska mreža]

Prikaz rezultata

- Želimo statističkim testom pokazati da smo postigli napredak
- Točnije želimo pokazati da je sredina „pojednostavljene“ neuronske mreže veća od rezultata mreže sa inicijalnim postavkama.

- Jednostrani T test za sredine (uz poznate varijance)
- Razina značajnosti 1%
- H_0 : *Sredina rezultata pojednostavljene neuronske mreže jednaka je sredini rezultata neuronske mreže inicijalne postavke*

- H_1 : *Sredina rezultata pojednostavljene neuronske mreže veća je od sredine neuronske mreže inicijalne postavke*

Prikaz rezultata

- Vrijednost testa je: 11.4215
- Kritična vrijednost t distribucije za $\alpha = 0.01$, $df = 198$ je 2.576.
- Odbacujemo nultu hipotezu u korist alternativne.
- Zaključak:

Sredina rezultata pojednostavljene neuronske mreže veća je od sredine neuronske mreže inicijalne postavke

Prikaz rezultata

- Također želimo statističkim testom pokazati da sredina rezultata neuronske mreže s ograničenjem na sigurne poteze se ne razlikuje bitno od sredine naše novo dobivene „pojednostavljene“ neuronske mreže.
- Dvostrani T test za jednakost sredina (uz poznate varijance)
- Razina značajnosti: $\alpha = 5\%$
- H_0 : *Sredina rezultata pojednostavljene neuronske mreže jednaka je sredini rezultata potpomognute neuronske mreže*
- H_1 : *Sredina rezultata pojednostavljene neuronske mreže različita je od sredine rezultata potpomognute neuronske mreže*

Prikaz rezultata

- Vrijednost testa je: -1.84618
- Kritična vrijednost t distribucije za $\alpha=0.025$, $df=198$ je 1.972 .
- Ne možemo odbaciti nultu hipotezu.
- Zaključak:

Sredina rezultata pojednostavljene neuronske mreže jednaka je sredini rezultata potpomognute neuronske mreže

Zaključak

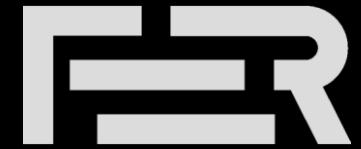
- Ipak nije se uspio dostignuti rezultat determinističkog algoritma.
- Za ovaj problem:
 - RMSProp optimizator postiže bolje rezultate od Adam-a
 - MSE kriterij daje malo bolje rezultate od kriterija absolutne greške
 - ReLU postiže značajno bolje rezultate od sigmoidalne prijenosne funkcije

Zaključak

- Najznačajniju razliku u brzini učenja i postignutim rezultatima su radile promjene na arhitekturi mreže!
- Povećanje broja slojeva neuronske mreže iznad jednog skrivenog sloja značajno pogoršava performanse mreže.
- U slučaju mreža sa dva skrivena sloja, mreže koje su imale veći broj neurona u drugom skrivenom sloju postizale su konzistentno lošije rezultate.

Zaključak

- Daljnje unaprjeđenje modela je vjerojatno moguće promjenom ulaznih parametara
- Neuronska mreža treba više podataka o trenutnom stanju
- Na primjer udaljenosti od hrane i prepreke umjesto zastavica ili davanje cjelokupne ploče kao matricu piksela



Hvala na pažnji!

ZAVRŠNI RAD br. 489

Pristupnik: Leo Goršić (0036523443)

Mentor: Marko Đurasević

Literatura

- [1] Goodfellow, I., Bengio, Y. and Courville, A., 2016. *Deep learning*. MIT press.
- [2] Bašić, B.D., Čupić, M. and Šnajder, J., 2008. Umjetne neuronske mreže. Zagreb: *Fakultet elektrotehnike i računarstva*.
- [3] Pratyaksha Jha, A Brief Overview of Loss Functions in Pytorch (2019, veljača). Poveznica: <https://medium.com/udacity-pytorch-challengers/a-brief-overview-of-loss-functions-in-pytorch-c0ddb78068f7> (pristupljeno 10. svibnja 2022.)
- [4] Jason Brownlee, Understand the Impact of Learning Rate on Neural Network Performance (2019., siječanj). Poveznica: <https://machinelearningmastery.com/understand-the-dynamics-of-learning-rate-on-deep-learning-neural-networks/> (pristupljeno 11. Svibnja 2022.)
- [5] Jason Brownlee, Gentle Introduction to the Adam Optimization Algorithm for Deep Learning (2017., srpanj). Poveznica: <https://machinelearningmastery.com/adam-optimization-algorithm-for-deep-learning/> (pristupljeno 8. Svibnja 2022.)

Literatura

- [6] Ayush Gupta, A Comprehensive Guide on Deep Learning Optimizers (2017., rujan).
Poveznica: <https://www.analyticsvidhya.com/blog/2021/10/a-comprehensive-guide-on-deep-learning-optimizers/> (prisupljeno 13. Svibnja 2022.)
- [7] Jason Brownlee, A Gentle Introduction to the Rectified Linear Unit (ReLU) (2019., siječanj).
Poveznica: <https://machinelearningmastery.com/rectified-linear-activation-function-for-deep-learning-neural-networks/> (pristupljeno 13. Svibnja 2022.)
- [8] <https://easyai.tech/en/ai-definition/gradient-descent/> (pristupljeno 30. Svibnja 2022.)
- [9] <https://github-wiki-see.page/m/SoojungHong/MachineLearning/wiki/Gradient-Descent>
(pristupljeno 30. Svibnja 2022.)
- [10] https://www.researchgate.net/figure/ReLU-activation-function_fig7_333411007 (pristupljeno 30. Svibnja 2022.)

Literatura

- [11] https://www.researchgate.net/figure/Logistic-sigmoid-function-Maps-real-numbers-to-the-interval-between-0-and-1_fig6_234049070 (pristupljeno 30. Svibnja 2022.)
- [12] <https://towardsdatascience.com/the-concept-of-artificial-neurons-perceptrons-in-neural-networks-fab22249cbfc> (pristupljeno 30. Svibnja 2022.)
- [13] <https://www.geeklingo.net/nokia-brings-snake-back-messenger/> (pristupljeno 30. Svibnja 2022.)
- [14] https://dribbble.com/tags/nokia_snake_game_design (pristupljeno 30. Svibnja 2022.)
- [15] <https://www.geeksforgeeks.org/intuition-of-adam-optimizer/> (pristupljeno 30. Svibnja 2022.)

Dodatci

- Rezultati NM s inicijalnim postavkama:
- $\bar{x} = 14.23 \quad S^2 = 76.69 \quad (\sigma = 8.76)$
- Rezultati determinističkog agenta:
- $\overline{x_{det}} = 52.12 \quad S_{det}^2 = 290.77 \quad (\sigma_{det} = 17.05)$
- Rezultati NM s ograničenjem na sigurne poteze (RMSProp,ReLU,L1):
- $\bar{x} = 36.01 \quad S^2 = 225.89 \quad (\sigma = 15.03)$

Dodatci

- Rezultati „povećane” NM (11x256x90x3, MSE, RMSProp, Sigmoida):
- $\bar{x} = 28.9 \quad S^2 = 152.1 \quad (\sigma = 12.37)$
- Rezultati „pojednostavljene” NM (11x256x3, MSE, RMSProp, ReLU):
- $\bar{x} = 32.32 \quad S^2 = 173.6 \quad (\sigma = 13.17)$

Dodatci

- Jednostrani T test za testiranje sredina (uz poznate varijance)
- $\alpha = 0.01, v = 198 \ df$
- $$t = \frac{\bar{x}_1 - \bar{x}_2 - d_0}{s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$
- H_0 : Sredina rezultata neuronske mreže arhitekture $11 \times 256 \times 3$ jednaka je sredini rezultata neuronske mreže arhitekture $11 \times 256 \times 40 \times 3$
- H_1 : Sredina rezultata neuronske mreže arhitekture $11 \times 256 \times 3$ veća je od sredine neuronske mreže arhitekture $11 \times 256 \times 40 \times 3$

Dodatci

- $\bar{x}_1 = 14.24, s_1 = 8.76, n_1 = 100$
- $\bar{x}_2 = 32.31, s_2 = 13.17, n_2 = 100$
- $s_p = \sqrt{\frac{99*76.7+99*173.60}{100+100-2}} = 11.18705$
- $t = \frac{32.31 - 14.24}{11.18705 * \sqrt{2 * \frac{1}{100}}} = 11.4215$
- Kritična vrijednost t distribucije za $\alpha = 0.01, df = 198$ je 2.576.

Dodatci

- Dvostrani T test za jednakost sredina (uz poznate varijance)
- $\alpha = 0.05, \nu = 198 \text{ } df.$
- $$t = \frac{\bar{x}_1 - \bar{x}_2 - d_0}{s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$

Dodatci

- H_0 : Sredina rezultata neuronske mreže arhitekture $11 \times 256 \times 3$ jednaka je sredini neuronske mreže arhitekture $11 \times 256 \times 40 \times 3$
- H_1 : Sredina rezultata neuronske mreže arhitekture $11 \times 256 \times 3$ različita je od sredine rezultata potpomognute neuronske mreže arhitekture $11 \times 256 \times 40 \times 3$
- $\bar{x}_1 = 36.01, s_1 = 15.03, n_1 = 100$ $s_p = \sqrt{\frac{99*225.89+99*173.60}{100+100-2}} = 14.13312$
- $\bar{x}_2 = 32.31, s_2 = 13.17, n_2 = 100$ $t = \frac{32.31 - 36}{14.13312 * \sqrt{2 * \frac{1}{100}}} = -1.84618$
- Kritična vrijednost t distribucije za $\alpha = 0.025, df = 198$ je 1.972.