


Razvoj agenta za igru zmija

Hana Smoković

Mentor: doc. dr. sc. Marko Đurasević

Igra Zmija

- cilj: postići što veći rezultat izbjegavajući prepreke
- glava zmije neprestano se pomiče naprijed
- moguća promjena smjera: ravno, lijevo i desno
- kad zmija pojede hranu, njezino tijelo se produlji za jedan segment




Slika 1: Prikaz igre Zmija na mobilnom telefonu Nokia

Motivacija

- ljudski mozak - jako velik broj neurona koji paralelno obrađuju podatke
- razvoj sustava s arhitekturama sličnim arhitekturi mozga
- **umjetna neuronska mreža:**
 - ne definira se način na koji treba obrađivati podatke
 - sama uči složene obrasce i donosi odluke na temelju ulaznih podataka

Umjetni neuron

- skalarni produkt vektora ulaza i vektora težina ulaz je prijenosne funkcije
- prijenosna funkcija daje konačni izlaz neurona
- **sigmoidalna** funkcija:
 - $sigm(net) = \frac{1}{1+e^{-net}}$



Slika 2: Grafički prikaz sigmoidalne funkcije

Neuronska mreža

- velik broj međusobno povezanih umjetnih neurona
- potpuno povezana unaprijedna slojevita
- arhitekture $6 \times 20 \times 3$ i $6 \times 50 \times 3$
- ulazni, skriveni i izlazni sloj

Neuronska mreža

- značenje elemenata ulaznog vektora:
 - postoji li opasnost lijevo od zmije
 - postoji li opasnost desno od zmije
 - postoji li opasnost ravno ispred zmije
 - udaljenost glave zmije od hrane u slučaju da skrene lijevo
 - udaljenost glave zmije od hrane u slučaju da skrene desno
 - udaljenost glave zmije od hrane u slučaju da nastavi ravno

Neuronska mreža

- neuronska mreža vraća vektor duljine 3
- tri moguća izlaza:
 - zmija nastavlja kretanje ravno za izlaz [1, 0, 0]
 - zmija skreće lijevo za izlaz [0, 0, 1]
 - zmija skreće desno za izlaz [0, 1, 0]

Genetski algoritam

- rješavanje optimizacijskih problema
- optimizira težine neuronske mreže s ciljem maksimiziranja dobrote
- korišten generacijski genetski algoritam

Elitizam

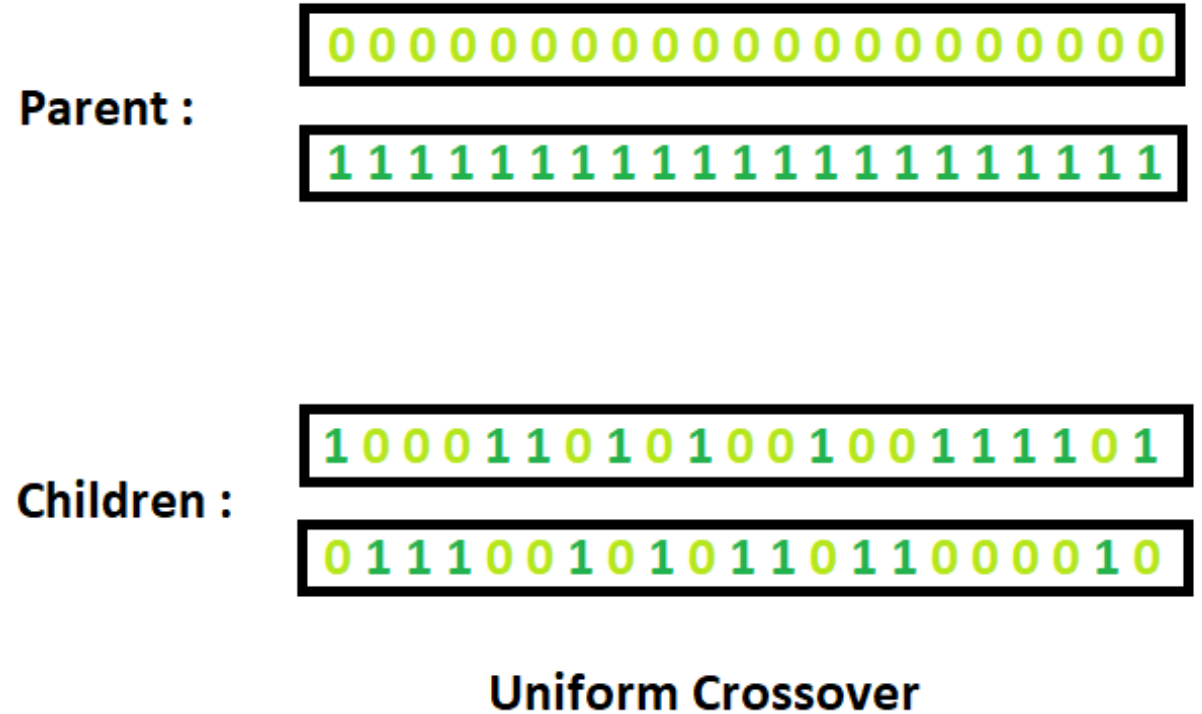
- karakteristika algoritma da ne može izgubiti najbolje rješenje
- prijenos najboljih 5 nepromijenjenih jedinki iz roditeljske populacije u novu

Selekcija

- odabir jedinki za križanje na temelju njihove kvalitete
- jedinke s većom dobrotom imaju veću vjerojatnost da budu odabrane
- **turnirska selekcija**
 - u turnir ulazi k jedinki, dok izlazi najbolja jedinka
 - najpoželjnija jedinka bit će jedinka iz turnira koja ima najveću dobrotu
 - korišteno je $k = 3$

Križanje

- kombinacija genetskog materijala roditelja
- **uniformno križanje:**
 - svaki gen se uzima od jednog roditelja
 - oba roditelja imaju jednaku vjerojatnost biti izabrana



Slika 3: Uniformno križanje

Mutacija

- slučajna promjena genetskog materijala jedinki stvorenih križanjem
- za svaki gen zasebno
- korištena vjerojatnost mutacije 0.1
- implementirano kao Gaussov šum



Implementacija

- napravljena u programskom jeziku Python
- izrađeno grafičko korisničko sučelje

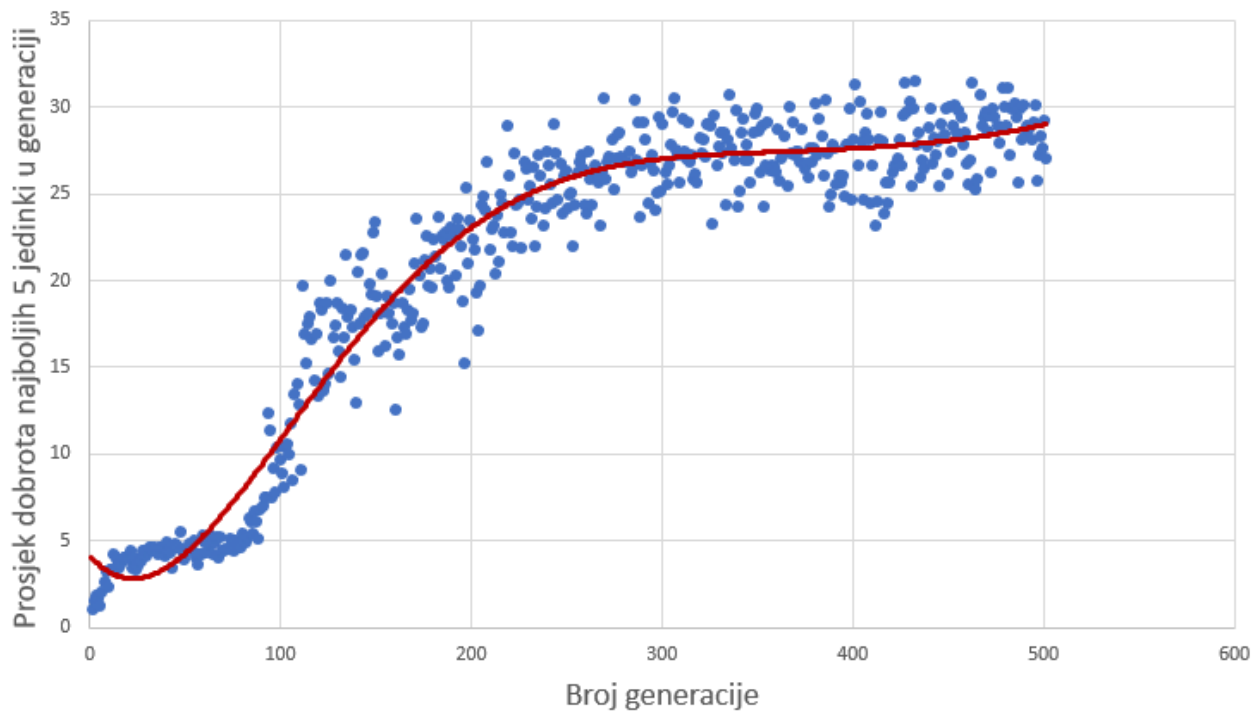
Slika 4: Prikaz implementacije igre Zmija

Rezultati

- treniranje na 500 generacija
- veličina generacije je 100 jedinki
- svaka jedinka igra Zmiju 3 puta kako bi dobila izračun funkcije dobrote
- dobrota je prosjek pojedene hrane u 3 pokretanja

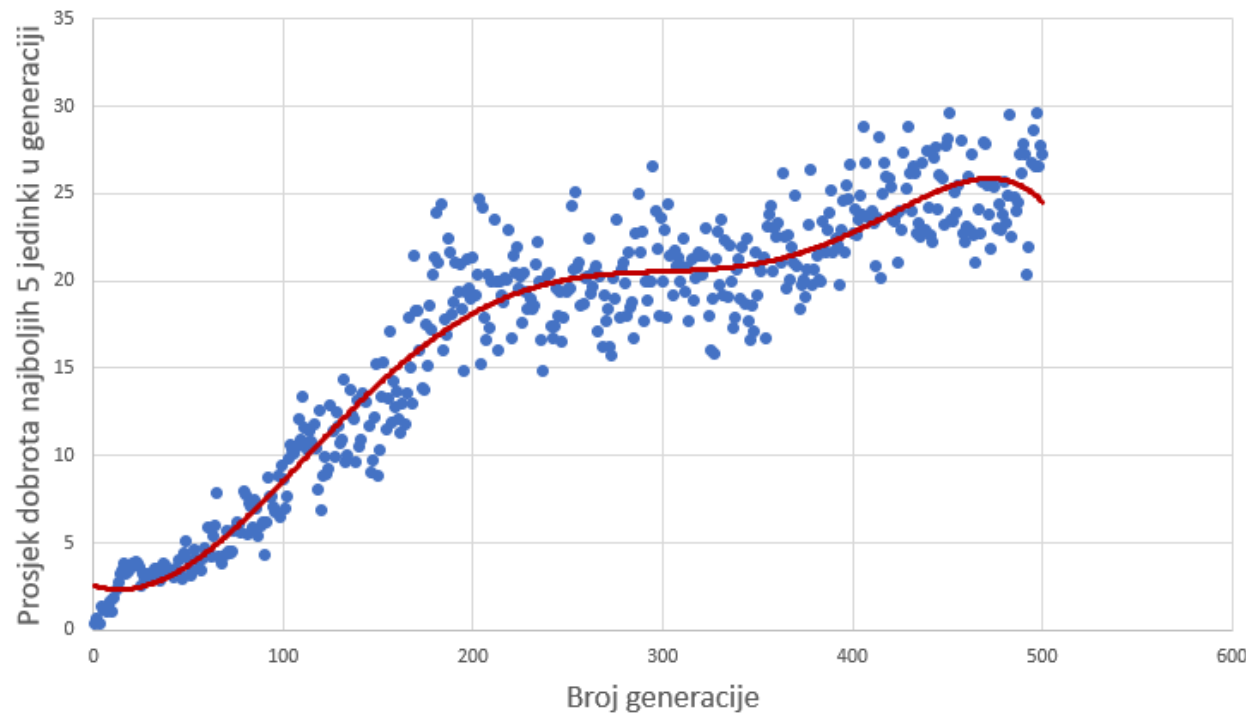
Rezultati

Prikaz faze treniranja s arhitekturom 6 x 20 x 3



Slika 5

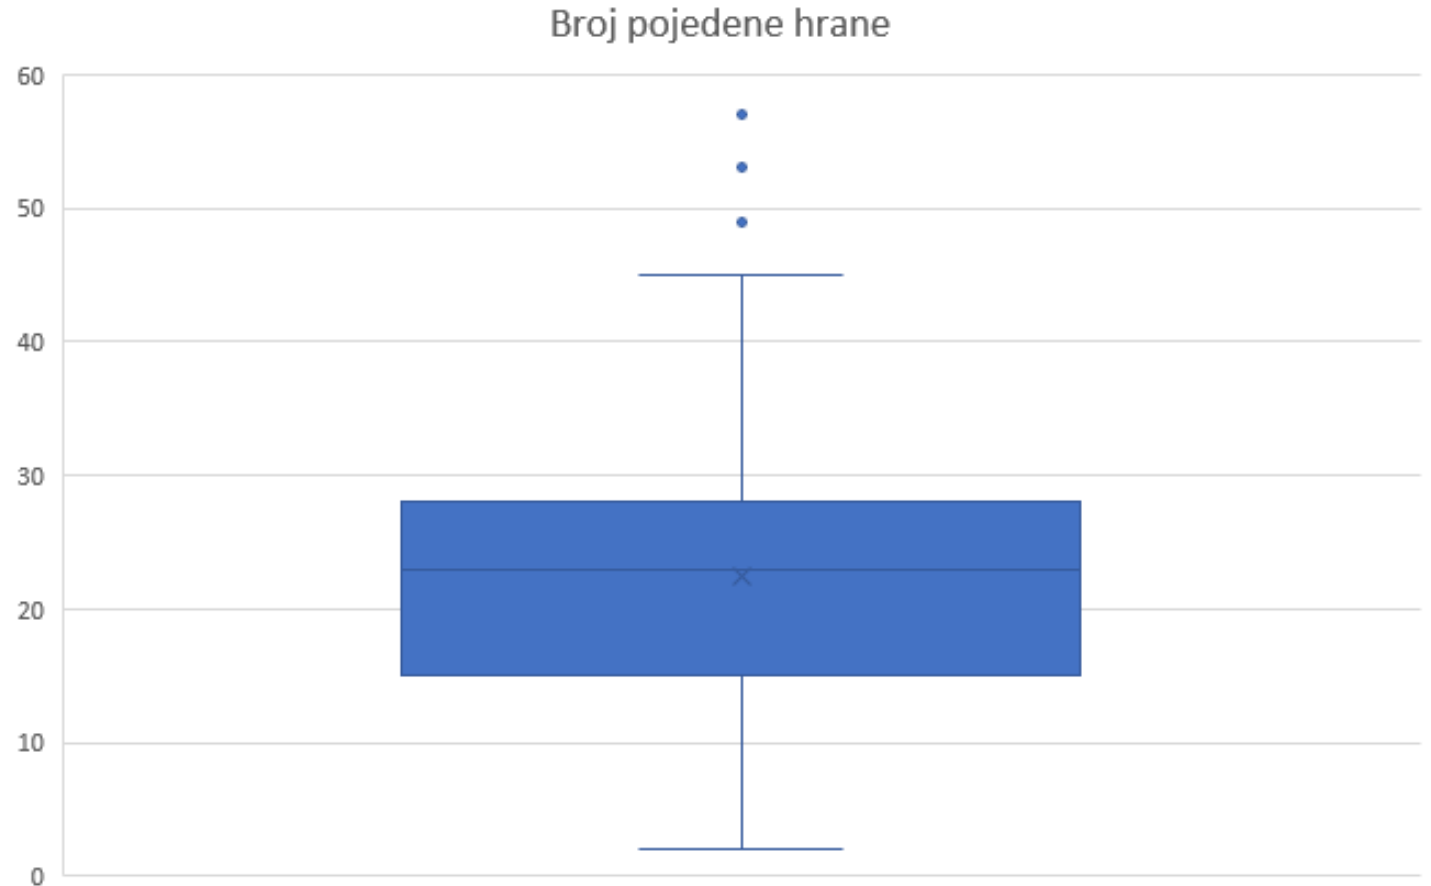
Prikaz faze treniranja s arhitekturom 6 x 50 x 3



Slika 6

Rezultati

- testiranje najbolje jedinice iz 500. generacije nakon treniranja s arhitekturom $6 \times 20 \times 3$
- jedinka igra 200 igara



Slika 7: Grafički prikaz broja pojedene hrane u fazi testiranja s arhitekturom $6 \times 20 \times 3$

Zaključak

- sporiji napredak na početku u fazi treniranja može upućivati na lošu inicijalizaciju parametara neuronske mreže
- genetski algoritam trebao bi uspjeti optimizirati težine, samo bi mu trebalo više vremena
- odabir jedne najbolje jedinice nije najbolji način evaluacije
- **daljnji rad:**
 - kvalitetniji ulazni podaci za neuronsku mrežu
 - dodatni slojevi i veći broj neurona u skrivenim slojevima
 - odabir drugačijih genetskih operatora

Hvala na pažnji!