SVEUČILIŠTE U ZAGREBU

FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

SEMINAR

Modeliranje jednostavnog vozača genetskim algoritmima

Mario Kostelac

Voditelj: *Domagoj Jakobović*

Zagreb, travanj, 2012.

Sadržaj

1. Sažetak

Evolucijsko računarstvo je novo područje računarstva temeljeno na osnovnim principima prirodne evolucije. Nastalo je 60-tih godina prošlog stoljeća, a danas se koristi kao robustan alat za rješavanje čitave familije problema za koje ne znamo pronaći učinkovite algoritme i optimalna rješenja. U seminaru je objašnjena osnovna ideja i značajke genetskih algoritama, dijela evolucijskog računarstva. Njime se u kasnijem dijelu modelira jednostavan model vozača, kojemu je u cilju naučiti savladati plošne staze. Analiza nekoliko izgrađenih staza pokazuje kako je jednostavni model, izgrađen kao konačni automat, sposoban savladati srednje komplicirane staze. Također su pokazana i ograničenja pri učenju tako izgrađenog modela.

2. Uvod

Industrija igara je zasigurno jedna od vodećih industrija u svijetu, a predviđanja stručnjaka koji promatraju tržišna kretanja konvergiraju misli da se ona samo penje na ljestvici najprofitabilnijih (Caron, 1998). Crysis, Need For Speed, PES, FIFA su vrlo poznati naslovi, no *postavlja se pitanje* bi li oni bili toliko dobri da su protivnici nedorasli, da trče u krivom smjeru ili iz nekog nepoznatog razloga skaču u vodu, umjesto da pucaju u vas?

U današnje vrijeme umjetna inteligencija je važna, općenito, ali i kao dio igara. Pitanje koje se nameće je kako programirati "mentalne sklopove" ostalih objekata u igrama? Umjetna inteligencija, kao čitava grana računarske znanosti, nudi mnoge pristupe izrade takvih modela. Jedan od njih je zasigurno i uporaba genetskih algoritama, jednostavnog koncepta prvi puta uporabljenog ranih 60-tih (Mitchell, 2009.).

Tema ovog seminara je modeliranje pojednostavljenog vozača koji upravlja vozilom u plošnom svijetu konstruiranim u obliku jednostavne staze. Generalizirani problem se naziva "Evolucija praćenja staze" (eng. Evolution of Corridor Following Behavior).

U sljedećem se poglavlju opisuju osnovni pojmovi vezani za genetske algoritme, a nakon toga se kreće u modeliranje jednostavnog vozača koji bi trebao biti u mogućnosti snaći se na stazi.

3. Genetski algoritmi kao logički skok u računarstvu

“Može li računalo reproducirati samo sebe?” pitanje je na koje će mnogi odgovarati negativno. Do zaključka da to nije sasvim točan odgovor, došao je von Neumann 60-tih godina 20. stoljeća. Skupina znanstvenika i entuzijasta toga doba počela je razmatrati koncept programiranja pomoću kojeg će program znati prepoznati okolinu te se ponašati u skladu s njom, ali isto tako i odrediti što bi bilo dobro učiniti u nekoj novoj situaciji (Mitchell, 2009.).

Promatranjem mehanizama evolucije, križanja, mutacija i prirodne selekcije stvoreno je novo područje računarske znanosti - *evolucijsko računarstvo*. *Takvo računalo* spremno je odgovoriti na zadani problem. Genetski algoritmi, kojima se rješavaju problemi ovog seminara, dio su evolucijskog računarstva.

U nastavku seminara objašnjava se osnovni koncept genetskih algoritama te pojmovi koji su neizostavni za razumijevanje daljnjeg dijela seminara.

3.1. Ideja

Ideja genetskih algoritama je provođenje umjetne evolucije na računalu u svrhu optimiziranja određenih problema ili generiranja rješenja za probleme na koje čovjek teško daje optimalan odgovor.

U početku generiramo *početnu populaciju*, sastavljenu od više i manje dobrih jedinki koje su u određenoj mjeri spremne preživjeti situacije koje ju okružuju.

Jedinke opisujemo *kromosomima*, nakupinom svojstava jedinke populacije, koji u potpunosti opisuju ponašanje jedinke u određenoj situaciji.

Najbolje jedinke (*funkcija dobrote*) se snalaze i preživljavaju (*prirodna selekcija*). Preživljene jedinke se *križaju*, a tijekom križanja je moguća pojava *mutacije*. Cijeli proces generiranja se odvija dok ne dobijemo zadovoljavajuće rješenje ili dok ne prođe zadano vrijeme/broj koraka (*uvjet zaustavljanja)* (Mitchell, 2009.).

3.2. Početna populacija

Početna populacija je slučajno generirana populacija jedinki koja kreće u rješavanje zadanog problema. Veličina populacije, koja je najčešće fiksna tijekom generacija, ovisi o prirodi problem. Ona je bitan faktor u brzini konvergencije optimalnom rješenju. Manji broj jedinki u populaciji smanjuje raznolikost početnih rješenja, što osigurava bržu konvergenciju, ali ne nužno i dobar smjer. Manje populacije mogu vrlo brzo konvergirati, ali mogu generirati rješenja čija je korelacija s optimumom vrlo mala. Povećanje broja jedinki osigurava veću raznolikost i mogućnost dobre konvergencije, ali isto tako povećava vrijeme izvođenja algoritma. Optimum ovog parametra se dobiva eksperimentalno i svojstven je prirodi problema i kombinaciji ostalih parametara algoritma.

Ako znamo u kojem se prostoru nalazi optimum, početna populacija se može generirati tako da ne bude sasvim slučajna, već da zadovoljava egzistenciju u okolišu predviđenog prostora rješenja

3.3. Umjetna selekcija

Tijekom života neke generacije, određene jedinke moraju umrijeti. Kako želimo da prežive dobre jedinke (elitizam), svakoj jedinci moramo pridružiti neki broj. Pridruživanje brojčane vrijednosti jedinci odrađuje *funkcija dobrote* – važan faktor uspješnosti pronalaženja rješenja. Eksperimentima je pokazano da guranje samo najboljih jedinki u sljedeću generaciju ne daje nužno optimalan rezultat pa se uvode *operatori selekcije*- funkcije/algoritmi odabira jedinki za preživljavanje.

Najčešće koristimo jedan od tri navedena operatora selekcije: generacijski jednostavni odabir (eng. roulette-wheel selection), turnirski odabir (tournament selection), elitistički odabir.

Generacijski jednostavni odabir (roullete-wheel selection) slaže dobrote jedinki na pravac tako da najveća dobrota zauzima najveći dio pravca. Odabir se vrši generiranjem slučajnog broja od 0 do kraja duljine. Treba primijetiti da najveća dobrota ima najveću vjerojatnost preživljavanja, ali isto tako da su nam za ovaj operator prihvatljive samo pozitivne vrijednosti dobrote.

Turnirski odabir se obavlja tako da se uzme n slučajno odabranih jedinki iz populacije, a u sljedeću generaciju kopira najboljih m (m<n).

Elitistički odabir se vrši tako da se kopira n najboljih u sljedeću generaciju.

Nakon generiranja baze sljedeće generacije, kreće se u križanje preživjelih (Golub, 1997.)

3.4. Križanje

Križanje je binarni operator. Kao parametre prima dvije jedinke (roditelje), a rezultat je novonastala jedinka (dijete) slična svojim roditeljima. Križanje se može dogoditi u jednoj ili više točaka prekida.

3.5. Mutacija

Mutacija je unarni operator koji se događa s određenom vjerojatnošću p_m. Prilikom mutacije se slučajno odabrani gen zamjenjuje nekim novim. Iako je mutacija najčešće štetna, postoje slučajevi kada ona daje poboljšanja konačnog rješenja. Priroda operatora mutacije usporava konvergenciju.

3.6. Uvjet zaustavljanja

Uvjet zaustavljanja je izraz koji određuje okončanje procesa evolucije. Može biti definiran postignutom dobrotom rješenja, brojem generacija, vremenski ograničenjem ili brojem iteracija bez značajnog poboljšanja.

Sada kada su objašnjeni svi potrebni parametri jednostavnog genetskog algoritma, pseudokod pojednostavljenog algoritma bi trebao biti nametnut sam od sebe.

```
Generiraj početnu populaciju
Izračunaj dobrotu svake jedinke u populaciji
Ponavljaj dok je uvjet zaustavljanja laž
     Odaberi najbolje jedinke operatorom selekcije
     Generiraj nove jedinke operatorima križanja i mutacije
     Izračunaj dobrotu svake jedinke u populaciji
     Zamijeni najlošije jedinke novorođenim
```

4. Modeliranje jednostavnog vozača

Cilj programskog dijela seminara je izgradnja sustava za modeliranje i simulaciju vožnje jednostavnog vozača. Sustav je izgrađen od dva veća dijela: PathBuildera i sustava za genetiku. *PathBuilder* je dio sustava zadužen za pripremu staze i grafičko simuliranje rezultata računanja. Sve poslove vezane za evolucijsko računarstvo obavlja *sustav za genetiku*.

4.1. PathBuilder

PathBuilder je dio sustava za izgradnju staze i simulaciju vožnje koju računa sustav za genetiku (opisano kasnije). Zbog poznavanja web tehnologija, njihove jednostavnosti i napredovanja HTML5 standarda (a time i canvas elementa), ovaj dio sustava je implementiran u web pregledniku (tehnologije: HTML + CSS + Javascript).

Izgradnja staza se obavlja definiranjem rubova ceste (s obje strane), kontrolnih točaka (eng. checkpoints) i početne linije putem jednostavno sučelja.

Simulacija se obavlja dovlačenjem generirane datoteke u prozor preglednika i pritiskom na tipku start.

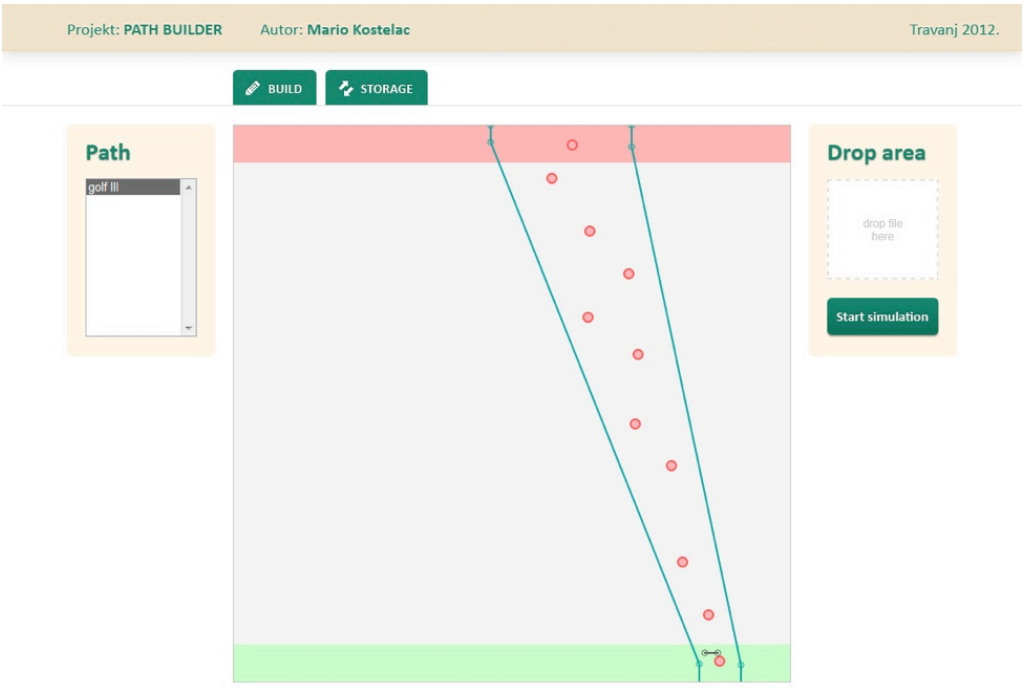

Slika 1 Sučelje PathBuildera

4.1. Sustav za genetiku

Sustav za genetiku je zbog zahtijevnosti operacija implementiran u programskom jeziku Java.

Sustav za genetiku obavlja najvažniji dio posla i programiran je generički. Model vozača, prirode i simulatora su apstraktni modeli. Posljedica toga je da uz male modifikacije, sustav u stanju pružiti okolinu za različite modele i implementacije vozača.

Kako je sustav u vrlo ranoj fazi razvoja, neće biti detaljno analiziran, ali se može naslutiti što pruža.

4.2. Komunikacija unutar sutava

Komunikacija između PathBuildera i ovog sustava ostvarena je pomoću tekstualnih datoteka. U tim datotekama se ključnim riječima i koordinatama određenih točaka prenose sve informacije o stazama i izračunatim vožnjama. Kako bi izvođenje genetskog algoritma u pregledniku zahtijevalo ponovno pisanje istog modela u JavaScriptu i stvorilo priličnu redundanciju, PathBuilder nakon procesa računanja dobiva gotova stanja koja treba animirati na prikladan način.

4.3. Model vozača

Evolucijsko računarstvo nas ni u kojem pogledu ne ograničava u pogledu implementacije odlučivanja o sljedećoj akciji modela. Zbog jednostavnosti izvedbe, prikazani model je implementiran kao Mealyev automat. To je konačni automat koji odluku o sljedećoj akciji donosi na temelju novopridošlih ulaza (automat ima samo jedno stanje).

4.3.1. Ulazi

Ulazi automata su numeričke vrijednosti koje vraćaju senzori – veza vozila i vanjskog svijeta. Analizirani model posjeduje samo jednu vrstu senzora – «lasere» koji mjere udaljenost između vozila i najbliže prepreke. Budući da broj mogućih ponašanja automata (objašnjeno kasnije) raste eksponencijalno s brojem senzora, a pokazalo se i da je manji broj senzora dovoljan za pravilno ponašanje u okolišu (Reynolds,

2000.), model posjeduje 3 fiksirana senzora raspoređena kao na slici. Senzori su idealizirani i sposobni su trenutačno izračunati udaljenosti.

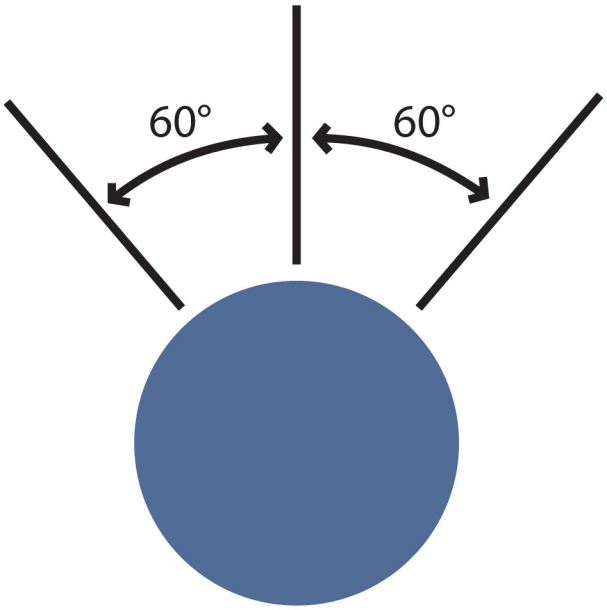

Slika 2 Raspored senzora

4.3.2. Odlučivanje o sljedećoj akciji

S obzirom da je cijeli model vrlo jednostavan, odlučivanje o sljedećoj akciji nije naročito kompliciranо. Pomoću trenutnih vrijednosti koje vraćaju senzori i vrijednosti trenutka prije (vrijeme je diskretizirano), model računa promjene udaljenosti na svakom od senzora. Dobivene razlike (silazne diferencije) linearno skalira tako da najveća promjena poprima vrijednost 8 (nazovimo je nekom vrstom razlučivosti) i na temelju tih novoizračunanih vrijednosti odlučuje što će sljedeće učiniti.

Pseudokod:

```
ocitajSenzore
promjene = sadasnjeVrijednosti – prosleVrijednosti
zapamtiSadanjeVrijednosti
sljedecaAkcija = dohvatiAkciju(promjene)
```

Ovakav način odlučivanja spada u skupinu greedy rješenja jer na odluku modela u svakom trenutku najviše utječe prepreka prema kojoj se najbrže približava. Kako je u stvarnosti automobil u nemogućnosti prečestih promjena smjera, tako je i ovaj model ograničen tako da svoju akciju možete donositi svakih n trenutaka (za prikazani model n = 10).

4.3.3. Moguće akcije

Model je sposoban izvesti samo tri akcije, a one sve djeluju na nastavak simulacije tako da modificiraju vektor brzine.

- nastavi: akcija ne mijenja vektor brzine
- skreni lijevo: akcija zakreće vektor brzine za kut +pi/8
- skreni desno: akcija zakreće vektor brzine za kut –pi/8

4.3.4. Zapis genotipa

Zapis genotipa ostvaren je pomoću trodimenzionalnog polja koje svakoj mogućoj kombinaciji promjena udaljenosti prepreka dodjeljuje jednu od definiranih akcija. Kako najveća promjena dobiva vrijednost 8 (također moguća i negativna vrijednost), imamo 2*8+1 različitih udaljenosti koje sustav mora moći razlikovati. Trodimenzionalnost je posljedica broja senzora (3 senzora), što inducira da je veličina genotipa (17*17*17 = 4913) i broj kombinacija koje pokrivamo eksponencijalno ovisan o broju senzora. Za opisani model broj različitih kombinacija je $3^{17*17*17}$, što približno iznosi $1.25*10^{2344}$. Ovako velik, *model* predstavlja ogroman izazov za pravilnu konvergenciju, ali pokazat će se da je mali broj kombinacija ključan pri pravilnoj vožnji staze.

4.4. Početna populacija

Kako bi dobili pitanje na odgovor «koliko je ovakav jednostavan model samostalno sposoban naučiti voziti?», početna populacija stvara se sasvim nasumično. Zbog velikog broja mogućih kombinacija veličina cijele populacije je velika i sadrži 1000

jedinki. Nakon što generiramo početnu populaciju, potrebno je ocijeniti njene jedinke *funkcijom dobrote.*

4.5. Funkcija dobrote

Funkcija dobrote za dodjelu konačne ocjene uzima nekoliko parametara u obzir:

- je li se vozilo slupalo,
- je li se vratilo u krivom smjeru,
- koliko je kontrolnih točaka ostavilo iza sebe
- koliko je napredovalo u vertikalnom smjeru.

Vrlo je lako prepoznati koja ostvarenja događaju donose nagradu, a koja kaznu. Dodatno, ako se uspoređuju dvije jedinke, koje su obje uspješno odvozile stazu, bolja je ona koja je prešla manju udaljenost.

Vertikalno napredovanje po stazi inspirirano je *air efficiency* koeficiijentom (broj 5 u zadnjem izrazu) (Reynolds, 2000.).

```
private int calculateFitness() {

    int fitness = 0;

    fitness += (this.model.passedCheckpoints())*200;

    if (this.model.isCrashed())
        fitness -= 1000;

    if (this.getSimulationModel().getPosition().getY() < 1)
        fitness -= 1000;

    if (this.model.isFinished()) {
        fitness += 2000;
        fitness -= this.model.getDrivenDistance();
    }

    fitness += 5*(300 - new Double(this.model.getPosition().getY()).intValue());

    return fitness;

}
```

Slika 3 Implementacija funkcije dobrote

4.6. Selekcija

Selekcija jedinki vrši se primjenom dvorazinskog turnira. Četiri nasumično odabrane jedinke se sučeljavaju u dvije borbe, a pobjednici odlaze u finali. Pobjednik finala nagrađen je preživljavanjem u sljedeću generaciju. Turniri se održavaju dok god ne bude izgrađeno pola sljedeće generacije. Ovakav način selekcije osigurava rastuću (ili barem konstantu) srednju ocjenu generacije.

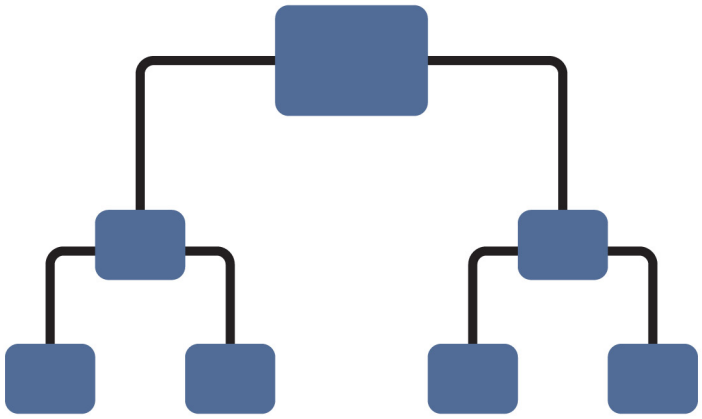

Slika 4 Shema turnirskog odabira

4.7. Križanje

Nakon selekcije se obavlja križanje parova preživjelih jedinki i «rađanje» novih kako bi se dobila potencijalno bolja rješenja. Križanje se odvija puknućem na jednom mjestu. Nakon što se slučajnim odabirom određuje mjesto puknuća, do tog mjesta dijete nasljeđuje gene jednog roditelja, a od tog mjesta nadalje gene drugog.

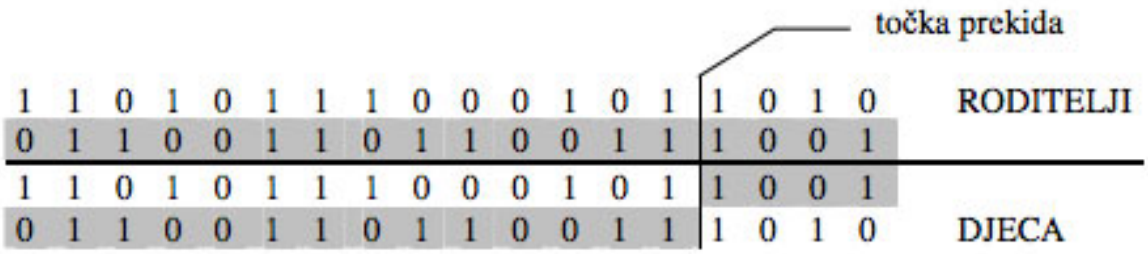

Slika 5 Križanje s jednom točkom prekida. Preuzeto iz (Golub, 1997.)

4.8. Mutacija

Mutacija se u zadanom slučaju događa s vjerojatnošću $p_k = 10^{-6}$, što nam omogućava jednostavan izračun da pri nekom križanju jedinka ostane nepromijenjena. Vrijednost te vjerojatnosti P({jedinka ostaje nepromijenjena}) = $(1-p_k)^{17*17*17}$. U sljedećoj tablici prikazana je vjerojatnost p_k i pripadajuću vjerojatnost P.

Tablica 1: Tablica vjerojatnosti mutacije

p_k	P
1.00E-03	0.73%
1.00E-04	61.18%
5.00E-05	78.22%
1.00E-05	95.21%
5.00E-06	97.57%
1.00E-06	99.51%

4.9. Podesivi parametri

Iako je sustav u ranoj fazi razvoja, glavni parametri jednostavnog genetskog algoritma su podesivi promjenom pripadajućih konstanti. Tako je moguće mijenjati veličinu generacije, maksimalni broj generacija, vjerojatnost mutacije, broj senzora automobila, kut zakreta i kut koji automobil pokriva senzorima. Mijenjanje ponašanja automobila zahtijeva poznavanje Jave. Novi modeli vozača mogu koristiti gotove senzore za udaljenost koji se ponašaju na već opisan način.

5. Analiza uspješnosti

U ovom poglavlju analiziraju se slučajevi učenja modela na nekoliko različitih staza uz prikaz konvergencije i izgleda staze. Parametri pri evoluiranju ponašanja vozača su:

- veličina generacije: 1000
- maksimalni broj generacija: 20
- vjerojatnost mutacije: 10^{-6}

5.1. Staza 1

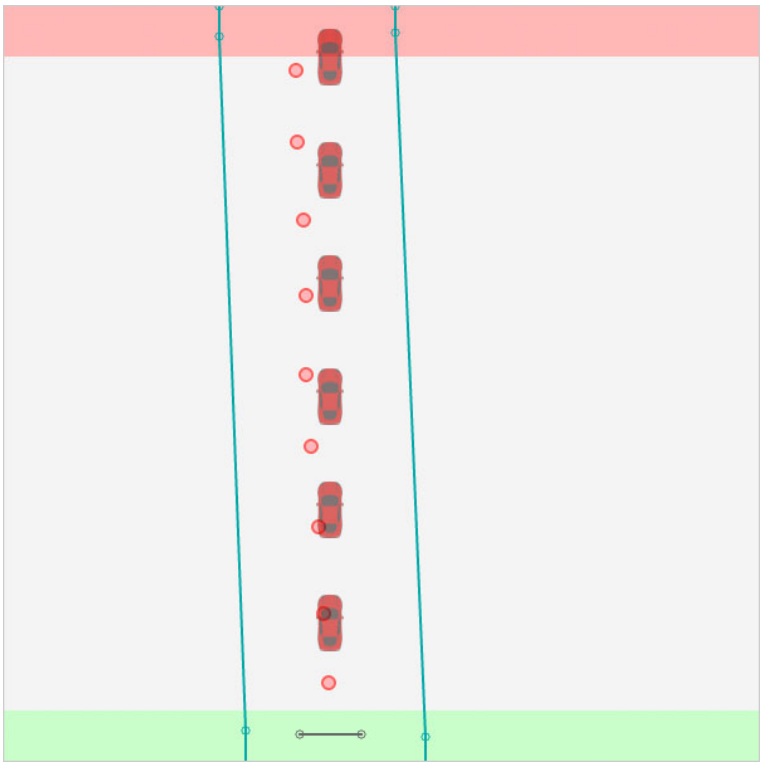

Slika 6. Simulacija jedinke prve generacije

Kako je vidljivo s priložene slike, prva staza nije bila nikakav izazov za opisani model vozača. Već u prvoj generaciji je pronađen model koji je odvozio kao na slici.

5.2. Staza 2

Kako potpuno ravna staza nije nikakav problem za modeliranog vozača, sljedeća je modelirana s blagim zavojem. Kao i na slici, već prva generacija je polučila jedinkom koja je sposobna stazu odvoziti do kraja. Simulacija najbolje jedinke prikazana je na slici. Graf konvergencije izostaje zbog lakog savladavanja izgrađene staze.

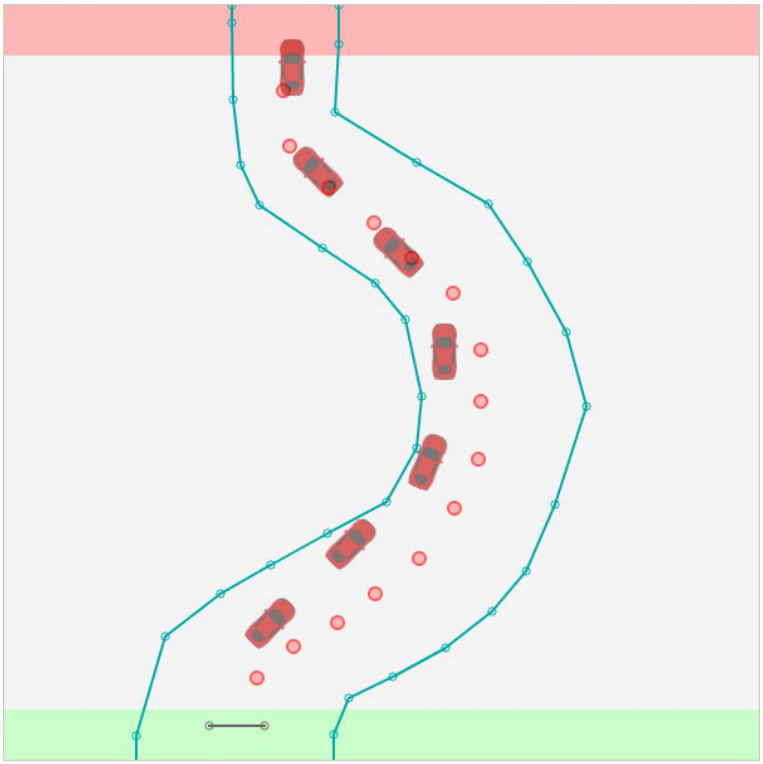

Slika 7 Simulacija najbolje jedinke prve generacije

5.3. Staza 3

Treća staza je kompliciranija nego druga. Dodan je jedan oštriji sa širokom stranom kao mamcem. Slijede slike simulacije.

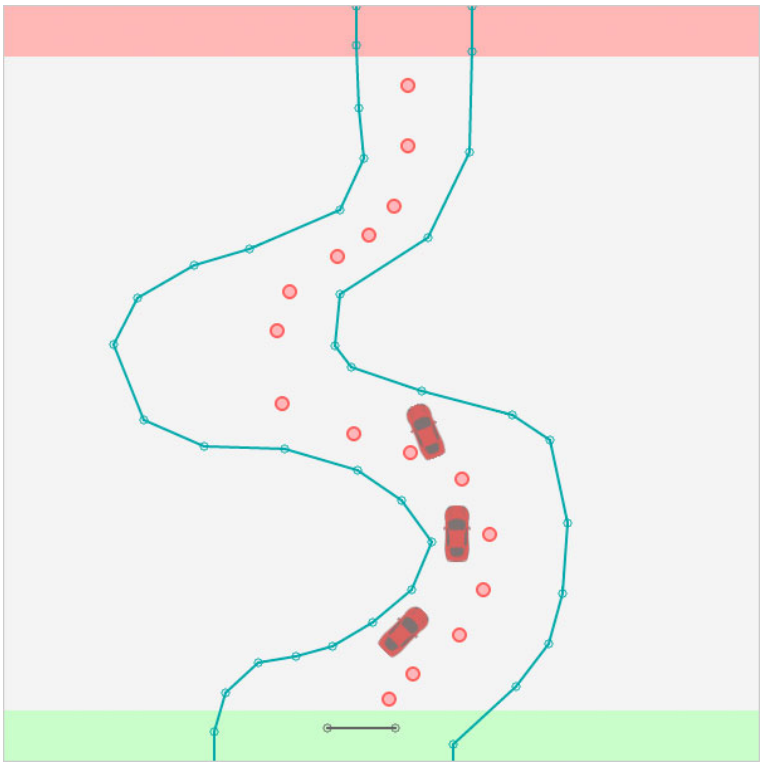

Slika 8 Simulacija najbolje jedinke prve generacije

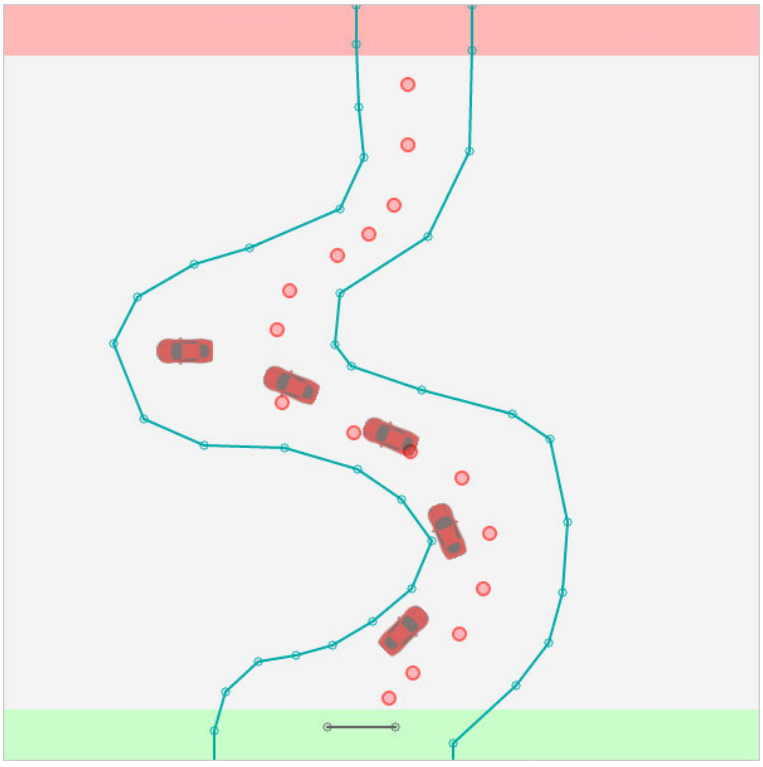

Slika 9 Simulacija najbolje jedinke 4. generacije

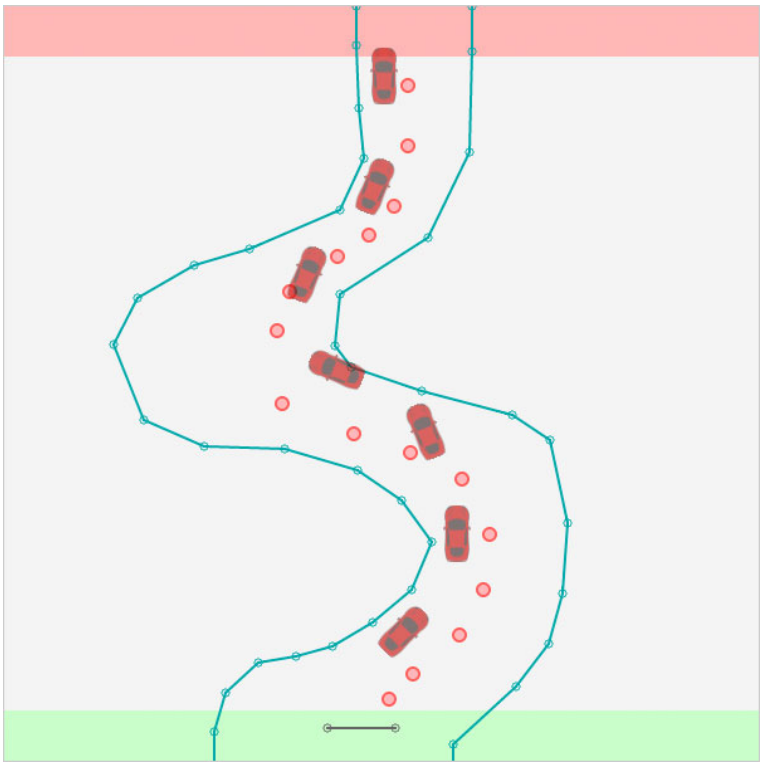

Slika 10 Simulacija najbolje jedinke 5. Generacije

Iako je predviđeno da bi model trebao biti sposoban naučiti u 20 generacija, model je savladao stazu već u 5. generaciji. Slijedi graf konvergencije funkcije dobrote.

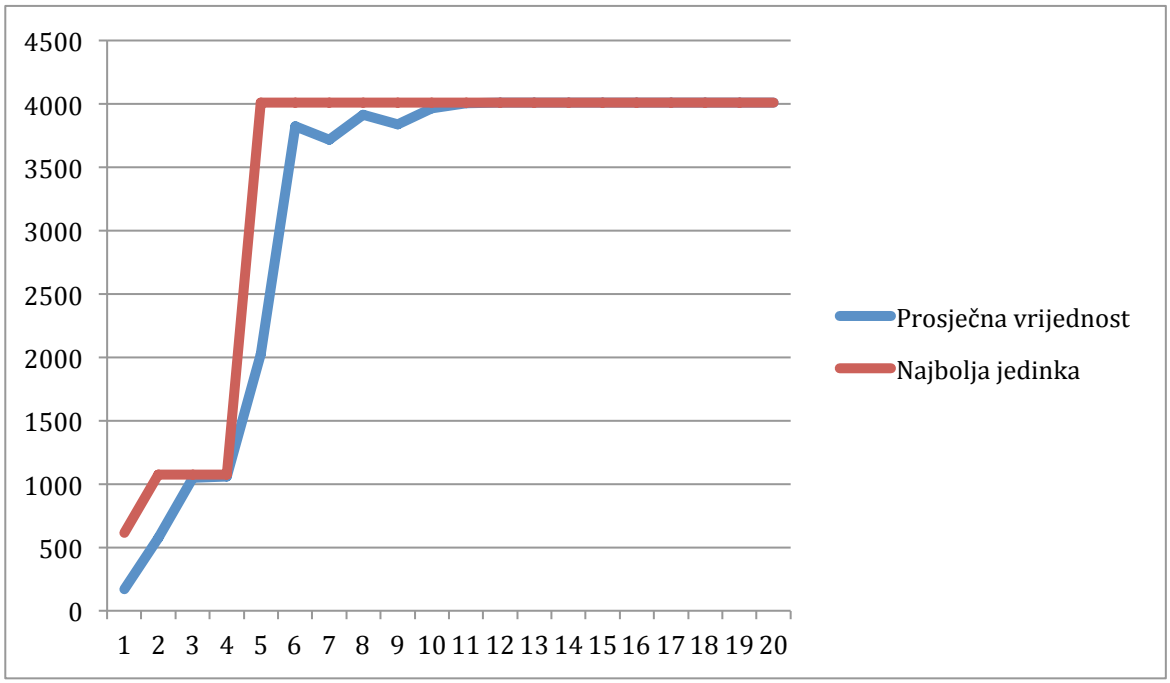

Graf 1 Funkcija dobrote

5.4. Staza 4

Četvrta staza koju model treba savladati je kompliciranija od prethodne i na određenim dijelovima ima poprilična suženja, čije bi savladavanje moglo predstavljati problem.

Slika 11 Simulacija najbolje jedinke 1. generacije

Slika 12 Simulacija najbolje jedinke 6. generacije

Slika 13 Simulacija najbolje jedinke 20. generacije

Sa slika je vidljivo da model nije uspio savladati stazu ni nakon 20 generacija. Isto tako, vidljivo je da nakon 6. generacije ne postoje značajni pomaci u uspješnosti savladavanja.

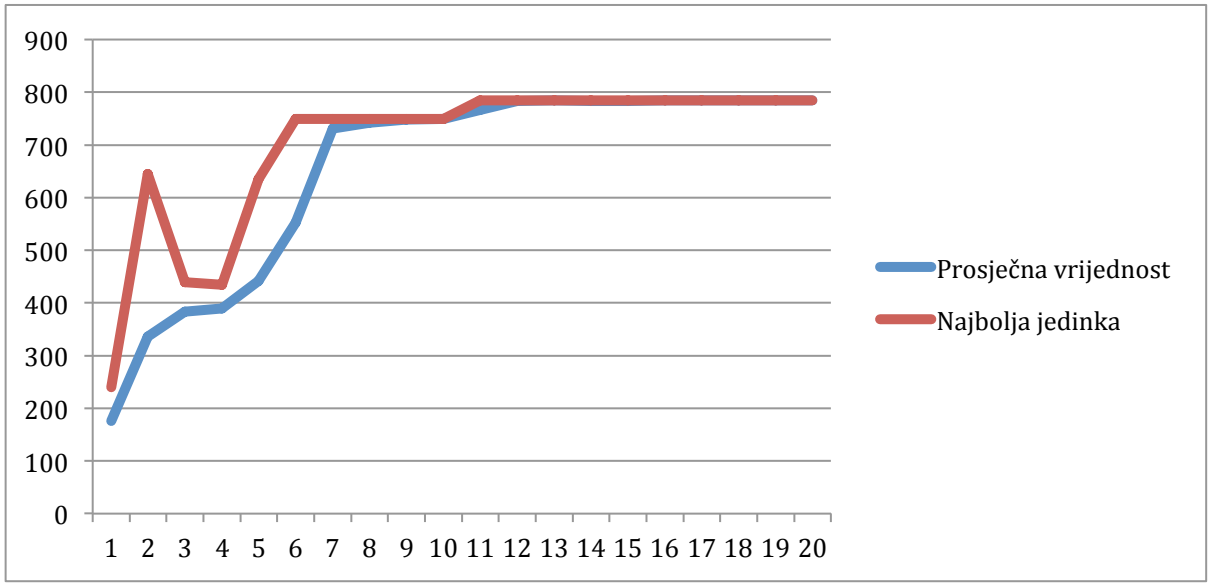

Graf 2 Funkcija dobrote

5.5. Staza 4 – ponovna simulacija

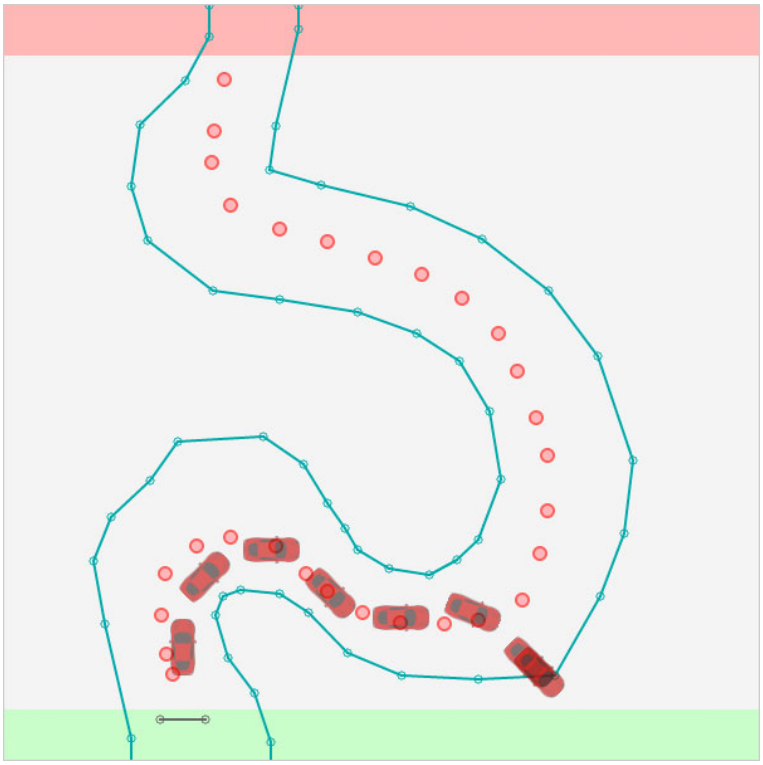

Slika 14 Prikaz simulacije 20. generacije nakon ponovljenog računanja

Slika 15 Prikaz simulacije 3. generacije modela dvostruko veće frekvencije očitavanja senzora

6. Zaključak

Genetski algoritmi pružaju mogućnost rješavanja problema za koje ne znamo postoji li optimalno rješenje ili ne znamo kojim pristupom krenuti kako bi do njega došli. Modeliranjem opisanog vozača pokazano je kako vrlo jednostavan pristup donosi zadovoljavajuće rezultate, ali i ograničenja jednostavnog modela.

7. Literatura

- Mitchell, M. Complexity: A guided tour, New York: Oxford University Press, Inc., 2009
- Golub, M. Genetski algoritmi, 1997, *http://www.zemris.fer.hr/~golub/ga/ga_skripta1.pdf*
- Reynolds, C. Evolution of Corridor Following Behavior in a Noisy World, 2000., *http://www.red3d.com/cwr/papers/1994/sab94.html*
- Wikipedia, http://en.wikipedia.org/wiki/Genetic_algorithm
- Caron, F. Gaming expected to be a $68 billion business by 2012., 9. Studenog 2010.
- Jakobović, D., Genetski algoritmi – predavanje, 24. travnja 2007., *http://www.zemris.fer.hr/~yeti/studenti/GA%20predavanje.pdf*