

# Adaptivno upravljanje izoliranim semaforiziranim raskrižjem primjenom neuronskih mreža

---

Miletić, Mladen

Master's thesis / Diplomski rad

2019

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **University of Zagreb, Faculty of Transport and Traffic Sciences / Sveučilište u Zagrebu, Fakultet prometnih znanosti**

*Permanent link / Trajna poveznica:* <https://urn.nsk.hr/urn:nbn:hr:119:502434>

*Rights / Prava:* [In copyright](#)/[Zaštićeno autorskim pravom.](#)

*Download date / Datum preuzimanja:* **2025-03-13**



*Repository / Repozitorij:*

[Faculty of Transport and Traffic Sciences - Institutional Repository](#)



**SVEUČILIŠTE U ZAGREBU  
FAKULTET PROMETNIH ZNANOSTI**

**Mladen Miletić**

**ADAPTIVNO UPRAVLJANJE IZOLIRANIM  
SEMAFORIZIRANIM RASKRIŽJEM PRIMJENOM  
NEURONSKIH MREŽA**

**DIPLOMSKI RAD**

**Zagreb, 2019.**

Zagreb, 4. travnja 2019.

Zavod: **Zavod za inteligentne transportne sustave**  
Predmet: **Umjetna inteligencija**

## DIPLOMSKI ZADATAK br. 5286

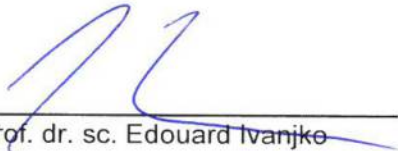
Pristupnik: **Mladen Miletić (0119010935)**  
Studij: **Inteligentni transportni sustavi i logistika**  
Smjer: **Inteligentni transportni sustavi**

Zadatak: **Adaptivno upravljanje izoliranim semaforiziranim raskrižjem primjenom neuronskih mreža**

### Opis zadatka:

Kako bi se postigla bolja razina uslužnosti semaforiziranog raskrižja moguće je primijeniti metode umjetne inteligencije u svrhu prilagodbe signalnog plana ovisno o trenutnom stanju na privozima izoliranog raskrižja. U radu je potrebno opisati problem prilagodbe signalnog plana, objasniti principe rada neuronskih mreža, prikazati vezu između simulacijskog alata PTV VISSIM i biblioteke AForge te izraditi algoritam za promjenu signalnog plana primjenom neuronske mreže.

Mentor:

  
\_\_\_\_\_  
izv. prof. dr. sc. Edouard Ivanjko

Predsjednik povjerenstva za  
diplomski ispit:

  
\_\_\_\_\_

Sveučilište u Zagrebu  
Fakultet prometnih znanosti

## **DIPLOMSKI RAD**

**ADAPTIVNO UPRAVLJANJE IZOLIRANIM  
SEMAFORIZIRANIM RASKRIŽJEM PRIMJENOM  
NEURONSKIH MREŽA**

**ADAPTIVE CONTROL OF ISOLATED SIGNALIZED  
INTERSECTION USING NEURAL NETWORKS**

Mentor: izv. prof. dr. sc. Edouard Ivanjko

Student: Mladen Miletić  
JMBAG: 0119010935

Zagreb, srpanj 2019.

# Zahvale

Zahvaljujem se svojem mentoru izv. prof. dr. sc. Edouardu Ivanjku na strpljenju, razumijevanju i pomoći tijekom pisanja ovog rada. Zahvaljujem se Tomislavu Erdeliću mag. ing. et techn. inf. za pomoć pri izradi simulacije i Krešimiru Kušiću mag. ing. traff. za pomoć pri implementaciji algoritma učenja. Također zahvaljujem svojoj obitelji, djevojci i prijateljima za potporu tijekom mog studiranja.

# Sažetak

**Naslov:** Adaptivno upravljanje izoliranim semaforiziranim raskrižjem primjenom neuronskih mreža

Zbog sve većeg rasta prometne potražnje u gradskim sredinama dolazi do značajnog smanjenja razine uslužnosti mobilnosti u gradskim sredinama. Dio problema su i zastarjeli sustavi upravljanja semaforiziranim raskrižjem zasnovani na ustaljenim signalnim planovima. Razvojem sustava zasnovanih na umjetnoj inteligenciji moguće je riješiti neke od problema upravljanja semaforiziranim raskrižjem. Korištenjem umjetne neuronske mreže i algoritma ojačanog učenja moguće je izgraditi sustav za adaptivno upravljanje semaforiziranim raskrižjem. U ovom radu je simulirano i analizirano izolirano semaforizirano raskrižje koristeći razvijeno simulacijsko okruženje uz algoritam ojačanog učenja zasnovanog na neuronskoj mreži. Iz rezultata se zaključuje da se korištenjem neuronskih mreža u kombinaciji s ojačanim učenjem mogu postići poboljšanja u upravljanju semaforiziranog raskrižja.

**Ključne riječi:** Inteligentni transportni sustavi, semaforizirano raskrižje, signalni plan, neuronske mreže, ojačano učenje.

# Abstract

**Title:** Adaptive Control of Isolated Signalized Intersection using Neural Networks

Due to increasing traffic demand in urban areas there is a significant decrease of the level of service of urban mobility. Part of the problem are old control systems of signalized intersection that use fixed signal programs. By developing systems based on artificial intelligence it is possible to solve some of the problems of signalized intersection control. With the use of artificial neural networks and reinforcement learning algorithms it is possible to create a system for adaptive control of a signalized intersection. In this thesis, an isolated signalized intersection is simulated and analyzed with the implementation of reinforcement learning algorithm based on neural networks. From the results it can be concluded that the use of neural networks and reinforcement learning algorithms can achieve improvements in signalized intersection control.

**Keywords:** Intelligent Transport Systems, Signalized Intersection, Signal Program, Neural Networks, Reinforcement Learning.

# Sadržaj

<b>1. Uvod</b>	<b>1</b>
<b>2. Problem upravljanja semaforiziranim raskrižjima</b>	<b>4</b>
2.1. Osnovni pojmovi prometnog inženjerstva . . . . .	4
2.2. Upravljanje semaforiziranim raskrižjem . . . . .	7
2.2.1. Osnovni model upravljanja semaforiziranim raskrižjem . . . . .	7
2.2.2. Strategije upravljanja semaforiziranim raskrižjem . . . . .	10
<b>3. Primjena umjetne inteligencije u upravljanju semaforiziranim raskrižjima</b>	<b>13</b>
3.1. Umjetna inteligencija . . . . .	13
3.2. Korištene metode umjetne inteligencije . . . . .	15
3.2.1. Osnove umjetnih neuronskih mreža . . . . .	16
3.2.2. Tehnike učenja neuronskih mreža . . . . .	18
3.2.3. Kohonenova samo-organizirajuća mapa . . . . .	19
3.2.4. Algoritmi ojačanog učenja . . . . .	22
3.3. Inteligentno upravljanje semaforiziranim raskrižjem . . . . .	25
<b>4. Adaptacija signalnog plana pomoću neuronske mreže</b>	<b>27</b>
4.1. Određivanje stanja prometne mreže . . . . .	27
4.2. Algoritam ojačanog učenja zasnovan na neuronskoj mreži . . . . .	28
<b>5. Simulacijsko okruženje PTV VISSIM/AForge</b>	<b>30</b>
5.1. Simulacijski alat PTV VISSIM . . . . .	30
5.2. Biblioteka za metode umjetne inteligencije AForge . . . . .	31
5.3. Simulacijsko okruženje NET TO VISSIM . . . . .	32
<b>6. Simulacijski rezultati</b>	<b>33</b>
6.1. Opis modela korištenog semaforiziranog raskrižja . . . . .	33



6.2. Postavke SOM mreže i Q-učenja . . . . .	36
6.2.1. Postavke SOM mreže . . . . .	36
6.2.2. Postavke Q-učenja . . . . .	40
6.3. Prikaz i analiza rezultata simulacije . . . . .	43
6.3.1. Scenarij 1 . . . . .	43
6.3.2. Scenarij 2 . . . . .	44
6.3.3. Scenarij 3 . . . . .	45
6.3.4. Ukupni rezultati po iteracijama učenja . . . . .	46
<b>7. Zaključak</b>	<b>49</b>
<b>Popis literature</b>	<b>50</b>
<b>Popis ilustracija</b>	<b>54</b>
<b>Popis tablica</b>	<b>55</b>
<b>Popis grafikona</b>	<b>56</b>

# 1. Uvod

Od svojeg začetka prometni sustav je zbog visoke razine interakcije među prometnim entitetima zahtijevao određenu razinu upravljanja. Zbog povećanog broja prometnih entiteta ta potreba za upravljanjem bila je najveća u gradskim sredinama. Privremeno i jednostavno rješenje problema bila su pravila prednosti prolaska koja su uspješno rješavala problem upravljanja prometa kod raskrižja. Daljnjim rastom gradskih sredina raste i potreba za mobilnošću odnosno mogućnošću za kretanjem od jednog mjesta do drugog [1]. Kao odgovor na povećanu mobilnost i probleme u prometnom sustavu osmišljen je semafor koji je postao prva telematička naprava u prometu. Iako se u početku semaforom upravljalo ručno, brzo je tehnološkim napretkom osmišljen elektronički semafor s mogućnošću samostalnog upravljanja raskrižjem primjenom unaprijed definiranog signalnog plana [2, 3]. Pri tome signalni plan može biti ustaljeni (nepromjenjiv) ili ga je moguće prilagoditi trenutnoj prometnoj situaciji (prometno ovisan odnosno adaptivni signalni plan).

Zbog ustaljenih signalnih planova semaforizirana raskrižja često ne mogu odgovoriti na stalne promjene u prometnom sustavu ili na pojavu incidentnih situacija. Kao rezultat nastaju adaptivni signalni planovi koji imaju mogućnost prilagodbe trajanja faza ovisno o stanju u prometnoj mreži [4]. Uz učestale izmjene signalnih planova moguće je ostvariti mnoge pozitivne učinke poput dodjele prioriteta javnom gradskom prijevozu i vozilima žurnih službi, kao i omogućiti učinkovitije odvijanje cjelokupnog prometnog sustava [4–7].

Naglim rastom broja privatnih prometnih entiteta i zakašnjelom reakcijom prilikom izgradnje sustava javnog gradskog prijevoza došlo je do pada razine uslužnosti i gradske mobilnosti, kao i do pojave brojnih ekoloških problema [1]. Zbog izravne povezanosti kapaciteta prometnice s brojem prometnih traka velik dio klasičnih prometnih rješenja uključivao je izgradnju dodatnih prometnih traka ili prometnica. Takva rješenja brzo dostižu vrhunac u već izgrađenim gradskim sredinama zbog nedostatka prostora za širenje prometne infrastrukture [2, 8]. Rješenje se vidi u nadgradnji prometnog sustava primjenom rješenja inteligentnih transportnih sustava (*engl. Intelligent Transport Systems, ITS*). Prema [9] ITS se može definirati kao holistička, upravljačka

i informacijsko-komunikacijska (kibernetiska) nadogradnja klasičnoga sustava prometa i transporta kojim se postiže znatno poboljšanje performansi, odvijanje prometa, učinkovitiji transport putnika i robe, poboljšanje sigurnosti u prometu, udobnost i zaštita putnika, manja onečišćenja okoliša, itd.

Taksonomija ITS-a prema standardu ISO TR 14813-1 određuje trinaest funkcionalnih područja ITS-a, pod koje pripada i upravljanje prometnim sustavom [10]. U funkciji upravljanja semaforiziranim raskrižjem sustavi upravljanja prikupljaju podatke o stanju prometne mreže i na temelju proračuna vrše izmjene u signalnom planu. Takvo upravljanje može biti izolirano na pojedinom raskrižju ili povezano komunikacijom više upravljačkih sustava u prometnoj mreži. Upravljački sustavi mogu biti zasnovani na pravilima, neizrazitoj logici, umjetnim neuronskim mrežama, genetskom algoritmu ili hibridnim ekspertnim sustavima.

Značajan problem pri stvaranju novih modela upravljačkih sustava je u slaboj mogućnosti testiranja sustava prije implementacije u prometnu mrežu. Problem postaje još izraženiji kod sustava zasnovanih na učenju koji sami stvaraju pravila upravljanja zbog velikog broja potrebnih iteracija učenja. U tu svrhu kao alat pri stvaranju novog upravljačkog sustava mogu se koristiti simulacijski modeli. Danas su dostupni razni programski alati za makroskopsko i mikroskopsko simuliranje prometnog sustava od kojih mnogi imaju mogućnost spajanja s vanjskim aplikacijama ili upravljačkim sustavima čineći tako potpuno simulacijsko okruženje [2, 8].

Cilj ovog diplomskog rada je prikazati problematiku upravljanja semaforiziranim raskrižjem te predstaviti mogućnost upravljanja izoliranim semaforiziranim raskrižjem primjenom umjetne neuronske mreže. U tu svrhu izrađen je simulacijski model izoliranog semaforiziranog raskrižja u simulacijskom alatu PTV VISSIM i upravljački algoritam uz korištenje programske biblioteke AForge [11, 12]. Ovaj je rad sastavljen od sedam poglavlja. U uvodnom poglavlju dan je opći pregled tematike te je predstavljen cilj i struktura rada. U drugom poglavlju opisana je problematika upravljanja semaforiziranim raskrižjima kao i neke od tehnika adaptivnog upravljanja. U trećem poglavlju opisane su tehnike umjetne inteligencije s naglaskom na njihovu primjenu u prometnom sustavu. U četvrtom poglavlju predložen je algoritam za upravljanje signalnim planom raskrižja uz primjenu neuronske mreže. U petom poglavlju opisano je simulacijsko okruženje za evaluaciju predloženog algoritma. U šestom poglavlju opisan je simulacijski model

te dobiveni simulacijski rezultati. U zadnjem poglavlju iznesen je zaključak prema prethodnim poglavljima.

## **2. Problem upravljanja semaforiziranim raskrižjima**

U ovom poglavlju je prikazana teorijska podloga prometnog inženjerstva, inteligentnih transportnih sustava te su opisani osnovni pojmovi potrebni za razumijevanje problema upravljanja semaforiziranih raskrižja. Također su pojašnjene osnovne strategije upravljanja semaforiziranim raskrižjem.

### **2.1. Osnovni pojmovi prometnog inženjerstva**

Kako bi se jasno mogla prikazati problematika upravljanja semaforiziranim raskrižjima potrebno je definirati osnovne pojmove vezane uz promet.

#### **Prometni sustav**


Prema [13] promet se može definirati kao stohastički sustav i proces čija je svrha obavljanje prijevoza i/ili prijenosa ljudi, roba i informacija u odgovarajućim prometnim entitetima zauzimanjem dijela prometnice prema unaprijed utvrđenim pravilima i protokolima. Promet je definiran kao stohastički sustav zbog njegove nepredvidivosti. Zbog stohastične prirode prometne probleme nije moguće uspješno rješavati na razini komponenata sustava. Kao rješenje je moguće primijeniti sustavski pristup i metodologiju prometnog inženjerstva [13].

#### **Poopćeni model prometnog sustava**

Kako bi se prometni sustav mogao izdvojiti iz okoline pri analizi prometnog sustava može se koristiti poopćeni model prometnog sustava kao početni model za opisivanje strukture i ponašanja sustava [13]. Takav model prikazan na slici 1 sastoji se od pet podsustava [13]:

1. Podsustav transportnih entiteta TrE (ljudi, roba ili informacija);
2. Podsustav adaptacije transportnih entiteta na prometni entitet;
3. Prometni entiteti TfE (automobil, avion, pješak, ATM-ćelija itd.);

4. Podsustav upravljanja prometom;
5. Podsustav prometne mreže.



Slika 1: Poopćeni model prometnog sustava [13]

Iz slike 1 je vidljivo da je podsustav upravljanja prometom direktno povezan s podsustavom prometne mreže i podsustavom prometnog entiteta. Iz toga se može zaključiti da upravljanje prometom direktno utječe na korisnost transformacije prostornih i vremenskih koordinata prometnog entiteta. Upravljanje prometom time utječe na vrijeme putovanja kroz mrežu koje se može prikazati izrazom [13]:

$$t_p = f(l_{OD}, TM, \varphi, C_i, NM, I_s), \quad (1)$$

gdje je:

$t_p$  - vrijeme putovanja [s];

$l_{OD}$  - udaljenost polazišta i odredišta [m];

$TM$  - topologija mreže;

$\varphi$  - veličina prometnog toka;

$C_i$  - kapacitet  $i$ -tog mrežnog elementa;

$NM$  - način upravljanja mrežom;

$I_s$  - utjecaj incidentnih situacija.

## Inteligentni transportni sustavi

ITS predstavlja skup kibernetičkih rješenja koja omogućuju informacijsku transparentnost, upravljivost i poboljšani odziv prometnog sustava čime on dobiva atribute inteligentnoga [9]. Termin inteligentni se odnosi na sposobnost sustava da adaptivno djeluje na nove promjenjive situacije u prometnom sustavu i da posjeduje sposobnost učenja iz rezultata svojih djelovanja. Iz tog razloga velik broj ITS rješenja i aplikacija koristi tehnike i koncepte umjetne inteligencije. ITS kao nadogradnja prometnog sustava postiže poboljšanje performansi klasičnoga prometnog sustava tako da vrijede relacije [9]:

$$PI_{ITS} > PI_{KL}, \quad (2)$$

$$QoS_{ITS} > QoS_{KL}, \quad (3)$$

gdje je:

$PI_{ITS}$  - indeks performansi inteligentnog prometnog sustava;

$PI_{KL}$  - indeks performansi klasičnog prometnog sustava;

$QoS_{ITS}$  - kvaliteta usluga inteligentnog prometnog sustava;

$QoS_{KL}$  - kvaliteta usluga klasičnog prometnog sustava.

Prometni sustav može postići razinu inteligentnog ponašanja jedino uz stvarnovremensku obradu podataka prikupljenih iz samog prometnog sustava [9]. Iz toga proizlazi da je pri projektiranju i gradnji prometne infrastrukture potrebno unaprijed predvidjeti ITS infrastrukturu za prikupljanje prometnih podataka, obradu istih, donošenje odluka i utjecanje na prometni sustav.

## 2.2. Upravljanje semaforiziranim raskrižjem

U današnje vrijeme dominantna tehnologija upravljanja raskrižjem je primjena semaforizacije. Današnji semafori uglavnom sadrže mikroprocesore u kojima je programski implementirana upravljačka logika. Takva upravljačka logika se sastoji od jednog ili više signalnih planova koji određuju način funkcioniranja semaforiziranog raskrižja. U nastavku je opisan osnovni model upravljanja semaforiziranim raskrižjem, ključni pojmovi potrebni za razumijevanje rada semafora te osnovne strategije upravljanja semaforiziranim raskrižjem.

### 2.2.1. Osnovni model upravljanja semaforiziranim raskrižjem

Osnovni model upravljanja semaforiziranim raskrižjem se sastoji od signalnog plana koji određuje raspored prema kojem se pojedinim prometnim tokovima dopušta prolazak kroz raskrižje. Za razumijevanje signalnog plana potrebno je definirati sve ključne elemente signalnog plana.

#### Signalni pojam

Signalni pojam je stanje koje određeni semafor može poprimiti. Zakon o sigurnosti prometa na cestama u Republici Hrvatskoj definira šest vrsta signalnih pojmova [14]:

1. **Crveno svjetlo** - Zabrana prolaska;
2. **Zeleno svjetlo** - Slobodan prolazak;
3. **Žuto svjetlo** - upaljeno samostalno, znači da vozilo ne smije prijeći crtu zaustavljanja niti smije ući u raskrižje, ako se u trenutku kad se žuto svjetlo pojavi, nalazi na takvoj udaljenosti od prometnog svjetla da se može na siguran način zaustaviti;
4. **Žuto svjetlo istodobno s crvenim** - označava skorbu promjenu svjetla i pojavu zelenog svjetla, ali ne mijenja zabranu prolaska koja je dana crvenim svjetlom;
5. **Žuto treptavo** - obvezuje sve sudionike u prometu da se kreću uz povećani oprez;
6. **Zeleno treptavo** - služi za upozorenje sudionika u prometu na skorbu prestanak slobodnog prolaska i na pojavu žutog, odnosno crvenog svjetla.



## Signalni ciklus

Signalni ciklus predstavlja trajanje signalnog plana odnosno vrijeme koje je potrebno da se izvrše sve faze definirane signalnim planom. U klasičnom pristupu duljina ciklusa se određuje prema broju faza koje su definirane signalnim planom, dok suvremeniji pristup prilagođava trajanje ciklusa prema trenutnom stanju u prometnoj mreži [15]. Minimalna duljina ciklusa je ograničena zbrojem zaštitnih međuvremena među fazama i minimalnog trajanja zelenog signalnog pojma. Maksimalno trajanje nije strogo definirano, ali se preporučuje trajanje ciklusa manje od 120 sekundi, osim u iznimnim situacijama kada nije moguće drugačije održivo upravljati semaforiziranim raskrižjima [15].


## Faza

Faza je dio ciklusa unutar kojeg pojedini prometni tokovi istovremeno imaju slobodan prolaz [15]. Faza počinje istovremeno s pojavom zelenog signalnog pojma i uključuje trajanje zelenog signalnog pojma kao i zaštitno međuvrijeme do početka sljedeće faze. U klasičnom pristupu redoslijed i trajanje pojedinih faza je fiksno, dok je uz adaptivno upravljanje moguće mijenjati trajanje pojedinih faza i/ili njihovog redoslijeda kako bi se postigao željeni učinak na prometni sustav. Takvom manipulacijom je moguće dodijeliti prioritet vozilima javnog gradskog prijevoza, dodijeliti prioritet vozilima žurnih službi ili smanjiti vrijeme čekanja na raskrižju [4–8].

## Zaštitno međuvrijeme

Zaštitno međuvrijeme je vrijeme unutar ciklusa koje osigurava da su sva vozila sigurno napustila raskrižje prije početka nove faze koja propušta prometne tokove koji su u konfliktu s prethodnim tokovima. Zaštitno međuvrijeme ovisi o tri komponente prikazane na slici 2 [2, 15]:

1. Provozno vrijeme ( $t_k$ ) - vrijeme od trenutka kraja zelenog svjetla do početka vremena pražnjenja odnosno ulaska vozila u raskrižje za vrijeme trajanja žutog svjetla ili na početku crvenog svjetla;
2. Vrijeme pražnjenja ( $t_p$ ) - vrijeme potrebno da vozilo prođe definiranu točku kolizije ( $T_k$ ) brzinom pražnjenja ( $v_p$ );
3. Vrijeme naleta ( $t_n$ ) - vrijeme potrebno da vozilo kojem se upali zeleno svjetlo prođe put naleta ( $s_n$ ) određenom brzinom naleta ( $v_n$ ).



Slika 2: Komponente izračuna zaštitnog međuvremena [7]

Zaštitno međuvrijeme može se izračunati prema izrazu:

$$t_z = t_k + t_p - t_n = t_k + \frac{s_p + l_v}{v_p} - \frac{s_n}{v_n}, \quad (4)$$

gdje je:

$t_z$  - zaštitno međuvrijeme [s];

$t_k$  - provozno vrijeme [s];

$t_p$  - vrijeme pražnjenja [s];

$t_n$  - vrijeme naleta [s];

$s_p$  - put pražnjenja [m];

$l_v$  - duljina vozila [m];

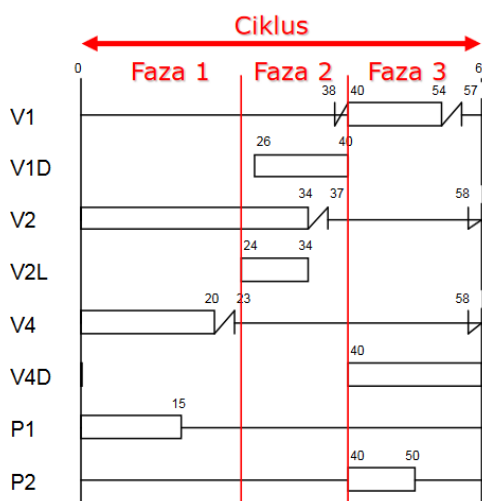
$v_p$  - brzina pražnjenja [m/s];

$s_n$  - put naleta [m];

$v_n$  - brzina naleta [m/s].

## Signalni plan

Signalni plan je detaljan pregled upravljačke logike za upravljanje raskrižjem. Sastoji se od signalnih grupa kojima je u vremenu prema fazama dodijeljen određeni signalni pojam. Zbog potrebe usklađivanja rada više raskrižja signalnom planu se može dodijeliti parametar otklon (engl. *offset*) koji predstavlja otklon početka trajanja signalnog plana od globalno definirane vremenske točke. Uz pravilno podešavanje otklona moguće je postići poboljšanja u protoku vozila kroz više ulančanih raskrižja [15]. Na slici 3 prikazan je ustaljeni signalni plan raskrižja. Pravokutnikom je definirano područje trajanja zelenog signalnog pojma. Crtom se prikazuje područje trajanja crvenog signalnog pojma dok se kosom crtom prikazuje područje žutog signalnog pojma.

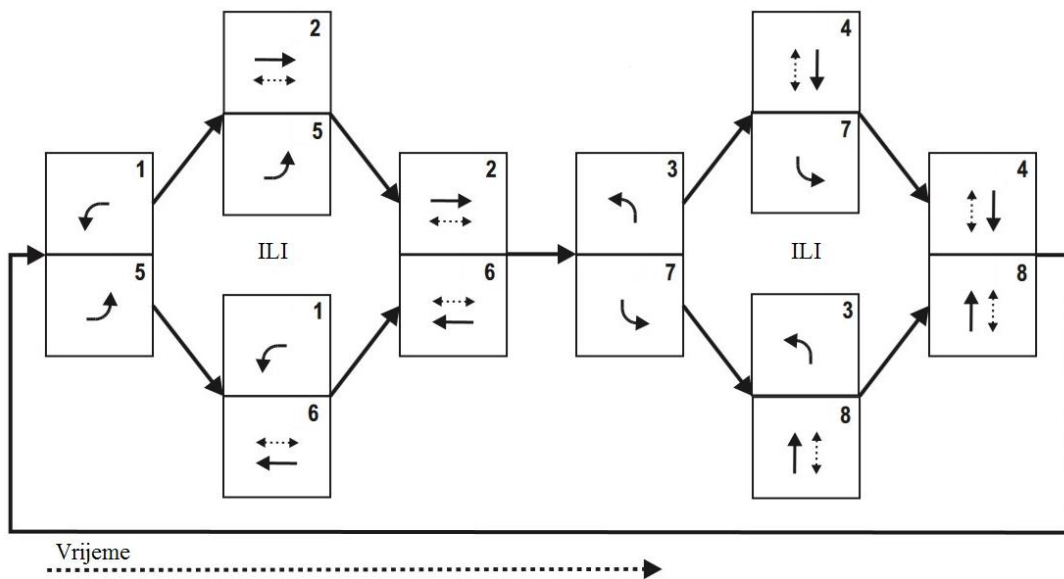


Slika 3: Primjer vremenski ustaljenog signalnog plana [16]

U današnje vrijeme se za prikazivanje signalnog plana sve više koristi NEMA (*engl. National Electric Manufacturers Association*) prstenasta struktura prikazana na slici 4. NEMA signalni plan se sastoji od niza ulančanih faza čiji redosljed nije ustaljen nego prometno ovisan pa je u takvoj strukturi moguće odrediti točke odluke na kojima se vrši odabir sljedeće faze [17, 18].

### 2.2.2. Strategije upravljanja semaforiziranim raskrižjem

Strategije upravljanja semaforiziranim raskrižjem su metode prema kojima se ostvaruju zadani ciljevi upravljanja raskrižjem. Takvi ciljevi mogu biti povećanje propusne moći, smanjenje zagušenja, dodjela prioriteta vozilima javnog gradskog prometa, dodjela prioriteta žurnim službama itd. Strategije se dijele na pasivne, aktivne i adaptivne [7].



Slika 4: Prikaz prstenastog NEMA signalnog plana [18]

### Pasivne strategije

Pasivne strategije koriste povijesne prometne podatke prikupljene za određeno raskrižje. Iz tih podataka se predviđaju trendovi ponašanja prometnog toka, te se prema tom trendu definira nov način izvršavanja signalnog plana. Ovim strategijama moguće je definirati različite signalne planove koji se izvode unutar zadanog vremenskog okvira. Najčešće se koriste pri određivanju signalnih planova za vrijeme jutarnjeg i poslijepodnevnog vršnog sata. Najprikladnije su za primjenu na lokacijama koje nemaju infrastrukturne mogućnosti za aktivno prikupljanje prometnih podataka. Neke od najčešće korištenih pasivnih strategija su [7]:

- Korekcija trajanja zelenog signalnog pojma;
- Razdvajanje faza;
- Korekcija trajanja ciklusa;
- Dodavanje faza.

### Aktivne strategije

Aktivne strategije koriste prometne podatke dobivene u stvarnom vremenu sa strateški pozicioniranih osjetila na raskrižju. Aktivne strategije određuju uvjete prema kojima se vrši kratkotrajna korekcija signalnog plana za vrijeme jednog ili više ciklusa. Zbog svoje jednostavnosti

i dobrog učinka ove strategije su jedne od najkorištenijih strategija upravljanja semaforiziranim raskrižjem. Neke od najčešće korištenih aktivnih strategija su [7]:

- Produljenje trajanja zelenog signalnog pojma;
- Raniji početak zelenog signalnog pojma;
- Dodavanje faza.

### **Adaptivne strategije**

Adaptivne strategije predstavljaju najvišu razinu strateškog upravljanja semaforiziranim raskrižjem. Adaptivne strategije koriste prometne podatke dobivene u stvarnom vremenu u kombinaciji s povijesnim prometnim podacima. Sinergijom tih podataka ove strategije stvaraju novi signalni plan koji najbolje odgovara trenutnom stanju u prometnoj mreži kako bi se ispunili i lokalni i globalni ciljevi upravljanja. Novi signalni plan moguće je odrediti korištenjem [7, 19]:

- Klasičnih optimizacijskih modela;
- Neizrazite logike;
- Genetskog algoritma;
- Neuronskih mreža.

## **3. Primjena umjetne inteligencije u upravljanju semaforiziranim raskrižjima**

U ovom poglavlju opisan je koncept umjetne inteligencije te su opisane korištene tehnike umjetne inteligencije.

### **3.1. Umjetna inteligencija**

Sve intenzivnijim razvojem računalnih sustava pojavljuje se mogućnost korištenja računala za rješavanje složenih problema čije se rješavanje ne zasniva isključivo na matematičkom izračunu, već i na donošenju odluka u ovisnosti o zadanim činjenicama. Kako bi takvi sustavi mogli donositi odluke potrebno je definirati bazu znanja koju će sustav koristiti pri donošenju odluka. Za bazu znanja može se reći da je ona apstraktni prikaz radne okoline u kojem sustav rješava zadatke [20]. Važan dio baze znanja su pravila zaključivanja s kojima sustav može donositi zaključke potvrđivanjem ili opovrgavanjem sudova. U trenutku kad je sustav u mogućnosti takvo znanje prikupljati i koristiti za rješavanje problema za njega se može reći da pokazuje značajke umjetne inteligencije.

Pregledom literature teško je pronaći ujednačenu definiciju umjetne inteligencije. Glavni problem koji se pojavljuje je činjenica da niti sam pojam inteligencije nije dovoljno definiran ni određen kako bi pomogao u definiranju umjetne inteligencije. Prema [21] umjetna inteligencija se definira kao dio računalne znanosti koja se bavi automatizacijom inteligentnog ponašanja, te je zasnovana na strukturama podataka, algoritmima primjene znanja i programskim tehnikama korištenih u njejoj implementaciji. Jednostavnije se može reći da je umjetna inteligencija sposobnost umjetnog sustava da se inteligentno ponaša. Inteligentno ponašanje umjetnog sustava se može odrediti kroz sljedeći skup sposobnosti [20]:


- Sposobnost stjecanja i uporabe znanja;
- Sposobnost postavljanja problema;
- Sposobnost učenja, zaključivanja, rješavanja problema;

- Sposobnost obrade i razmjene znanja.

Razvoj umjetne inteligencije uvelike je inspiriran ljudskom prirodom te ljudskim načinima obrade informacija i zaključivanja. Iz tog oponašanja ljudske inteligencije razvile su se različite tehnike umjetne inteligencije, od kojih se mogu izdvojiti: Neizrazita logika, genetski algoritmi, umjetne neuronske mreže i ojačano učenje. U praksi se često zajednički koristi nekoliko tehnika umjetne inteligencije uz bazu znanja izgrađenu za specifičnu domenu primjene. Takvi sustavi s ugrađenim stručnim znanjem nazivaju se ekspertni sustavi.

Stručnjaci raznih domena često u svojem radu koriste računalne sustave kao pomoć pri pronalasku rješenja određenog problema. Iako takvi sustavi uvelike ubrzavaju rad stručnjaka, oni su i dalje ovisili o stručnom znanju operatera, te nisu imali uvida u vrstu problema koju su rješavali i nisu imali mogućnost samostalne analize problema. U cilju zamjene stručnjaka s računalnim sustavom osmišljeni su ekspertni sustavi. Ekspertni sustavi se izrađuju za specifičnu namjenu, te se za njih izrađuje posebna baza znanja koja sadrži znanje isključivo iz domene problema kakve će sustav rješavati. Izrada ekspertnog sustava najčešće uključuje suradnju programera, inženjera znanja i stručnjaka domene za koje se sustav razvija. Osnovni model rada ekspertnog sustava prikazan je na slici 5.

Iz modela ekspertnog sustava vidljiva je razlika između baze znanja i baze podataka. Baza znanja sadrži znanje iz problemske domene koju su stvorili inženjer znanja i stručnjak iz domene. U osnovnom obliku ona se sastoji od AKO-ONDA pravila. Mehanizam zaključivanja provjerava u bazi podataka listu trenutnih činjenica koju upotpunjuje korištenjem baze znanja. Postupak zaključivanja je iterativan jer pojavom novih činjenica može doći do aktivacije novih pravila. Uz dovoljno široku bazu znanja mehanizam zaključivanja ponekad može i upotpuniti podatke koji nedostaju. Mehanizam objašnjavanja služi za pojašnjenje načina zaključivanja i interpretaciju dobivenih rezultata. Razvojno sučelje koristi inženjer znanja zajedno sa stručnjakom iz problemske domene kako bi upotpunili bazu znanja ekspertnog sustava i proveli evaluaciju njegovog rada. Nakon što je ekspertni sustav potpun može ga koristiti korisnik koji to radi kroz korisničko sučelje kroz koje može u sustav unijeti nove činjenice i kao izlaz dobiti rješenje problema.



Slika 5: Prikaz modela i okoline ekspertnog sustava [20]


### 3.2. Korištene metode umjetne inteligencije

Za izradu sustava adaptivnog upravljanja je u ovom diplomskom radu iskorištena Kohonova neuronska mreža i algoritam ojačanog učenja. U ovoj je cjelini opisan osnovni koncept umjetnih neuronskih mreža i metoda njihovih učenja te je nakon toga opisano korištenje Kohonove samo-organizirajuće mape kao posebne vrste neuronske mreže za određivanje stanja prometne mreže.




### 3.2.1. Osnove umjetnih neuronskih mreža

Koncept umjetnih neuronskih mreža se pojavljuje kao pokušaj imitacije neuronske strukture ljudskog mozga u nadi da će se uz dovoljan broj neurona uspješno imitirati ili čak nadmašiti ljudska inteligencija. Osnovna građevna jedinica biološke neuronske mreže je neuron prikazan na slici 6. Biološki neuron se sastoji od dendrita kroz koje dolaze ulazni signalni prema neuronu. Između dendrita i drugih neurona nalaze se sinapse koje svojim svojstvima mogu ubrzati ili usporiti prolazak signala prema dendritima. U jezgri se dobiveni signali kombiniraju u jedan koji se tada kroz akson šalje drugim povezanim neuronima.



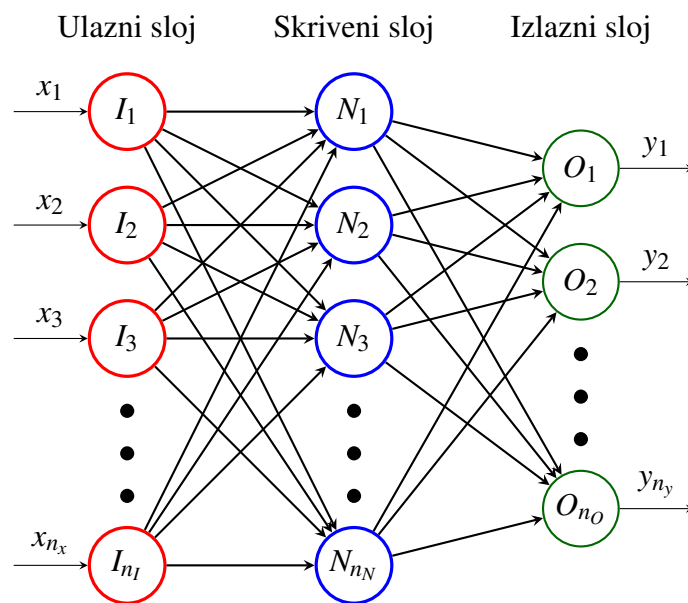
Slika 6: Prikaz biološkog neurona [20]

Po uzoru na biološki neuron modeliran je umjetni neuron prikazan na slici 7. U umjetnom neuronu ulazni signali se množe koeficijentom težine te se tada u jezgri zbrajaju i prolaze kroz aktivacijsku funkciju koja generira izlazni signal iz neurona. Neke od najčešće korištenih aktivacijskih funkcija su funkcija praga, funkcija predznaka i logistička (sigmoidna) funkcija [20].



Slika 7: Model umjetnog neurona [20]

Međusobnim ulančavanjem umjetnih neurona stvara se umjetna neuronska mreža. Topologija neuronske mreže se određuje prema njezinoj namjeni, a često se koristi slojeviti pristup za pojašnjenje topologije neuronske mreže prikazan na slici 8. Prikazani model sastoji se od ulaznog, skrivenog i izlaznog sloja. Ulazni sloj prima podatke iz okoline u obliku ulaznog vektora  $X = (x_1, x_2, x_3, \dots, x_{n_x})$  te ih prosljeđuje svakom neuronu skrivenog sloja. Skriveni sloj se koristi za obradu podataka. Svaki ulazni signal u neuron skrivenog sloja se množi sa zadanom težinom i zbraja prije prosljeđivanja aktivacijskoj funkciji koja generira izlaz iz neurona prema izlaznom sloju. Uloga izlaznog sloja je da okolini dostavi izlaz neuronske mreže u obliku izlaznog vektora  $Y = (y_1, y_2, y_3, \dots, y_{n_y})$ .



Slika 8: Model umjetne neuronske mreže s ulaznim, skrivenim i izlaznim slojem

Težine neurona skrivenog sloja  $W$  moguće je definirati  $n_I \times n_N$  matricom:

$$W = \begin{bmatrix} w_{1,1} & w_{1,2} & w_{1,3} & \cdots & w_{1,n_N} \\ w_{2,1} & w_{2,2} & w_{2,3} & \cdots & w_{2,n_N} \\ w_{3,1} & w_{3,2} & w_{3,3} & \cdots & w_{3,n_N} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ w_{n_I,1} & w_{n_I,2} & w_{n_I,3} & \cdots & w_{n_I,n_N} \end{bmatrix}, \quad (5)$$

gdje je:

$n_I$  - broj neurona ulaznog sloja;

$n_N$  - broj neurona skrivenog sloja.

Težine neurona izlaznog sloja  $Z$  definiraju se  $n_N \times n_O$  matricom:

$$Z = \begin{bmatrix} z_{1,1} & z_{1,2} & z_{1,3} & \cdots & z_{1,n_O} \\ z_{2,1} & z_{2,2} & z_{2,3} & \cdots & z_{2,n_O} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ z_{n_N,1} & z_{n_N,2} & z_{n_N,3} & \cdots & z_{n_N,n_O} \end{bmatrix}, \quad (6)$$

gdje je:

$n_O$  - broj neurona izlaznog sloja.

Uz pretpostavku da je aktivacijska funkcija svakog neurona funkcija identiteta  $f(x) = x$ , može se izraziti ovisnost izlaznog vektora neuronske mreže s ulaznim vektorom:

$$Y = Z \cdot W \cdot X, \quad (7)$$

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{n_y} \end{bmatrix} = \begin{bmatrix} z_{1,1} & z_{1,2} & z_{1,3} & \cdots & z_{1,n_O} \\ z_{2,1} & z_{2,2} & z_{2,3} & \cdots & z_{2,n_O} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ z_{n_N,1} & z_{n_N,2} & z_{n_N,3} & \cdots & z_{n_N,n_O} \end{bmatrix} \cdot \begin{bmatrix} w_{1,1} & w_{1,2} & w_{1,3} & \cdots & w_{1,n_N} \\ w_{2,1} & w_{2,2} & w_{2,3} & \cdots & w_{2,n_N} \\ w_{3,1} & w_{3,2} & w_{3,3} & \cdots & w_{3,n_N} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ w_{n_I,1} & w_{n_I,2} & w_{n_I,3} & \cdots & w_{n_I,n_N} \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ \vdots \\ x_{n_x} \end{bmatrix} \cdot (8)$$

Iz izraza 8 vidljivo je da preslikavanje ulaznog vektora na izlazni ovisi o iznosima težina neurona između slojeva. Prilagođavanjem iznosa tih težina može se neuronsku mrežu trenirati da na određeni ulazni signal daje željeni izlazni rezultat. Može se reći da težine neurona predstavljaju bazu znanja neuronske mreže.

### 3.2.2. Tehnike učenja neuronskih mreža

Učenje neuronskih mreža svodi se na prilagođavanja iznosa težina pojedinih neurona kako bi se na izlazu iz neuronske mreže dobio željeni izlaz. Tehnike učenja neuronskih mreža mogu se podijeliti na tehnike nadziranog učenja i ne-nadziranog učenja.

## **Nadzirano učenje**

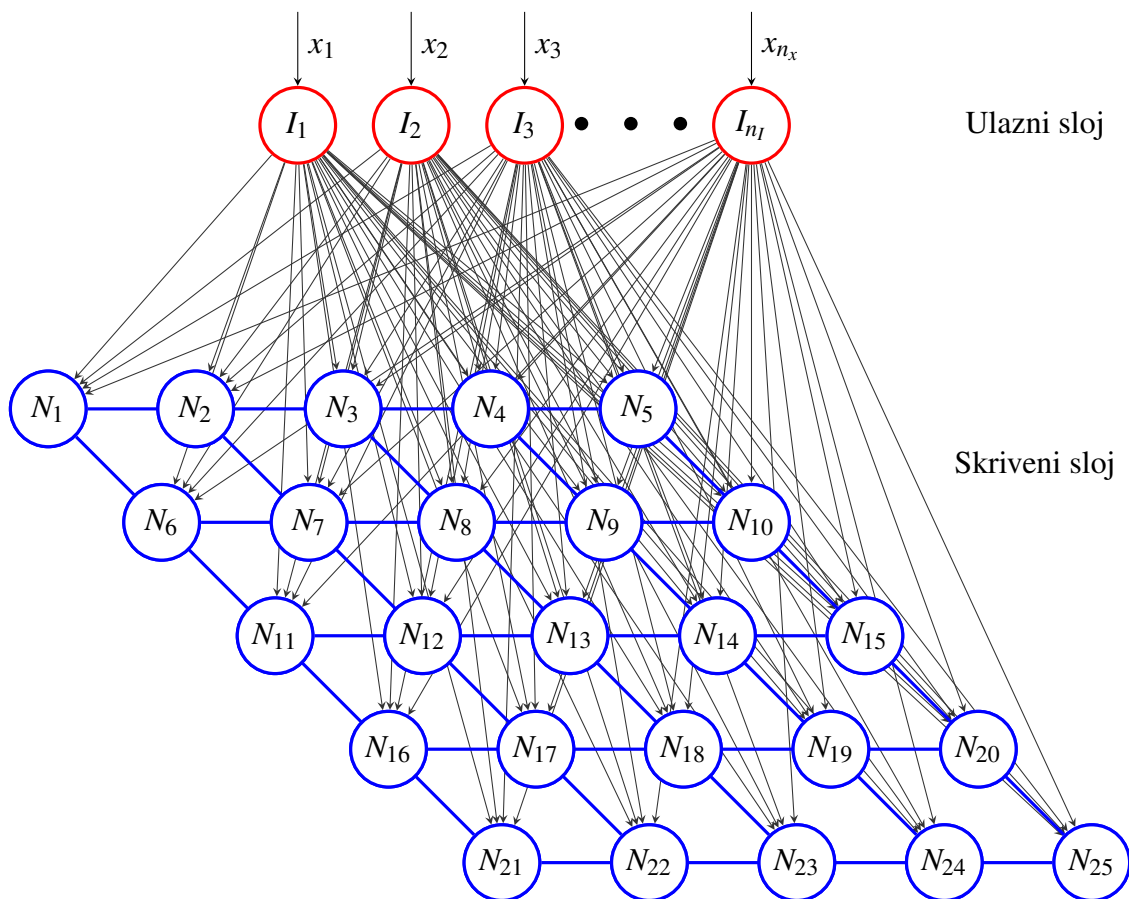
Nadzirano učenje najčešći je tip učenja neuronskih mreža. Osnovna ideja je da neuronsku mrežu uči vanjski učitelj korištenjem širokog skupa parova ulazno izlaznih vektora. Neuronska mreža podešava težine svojih neurona dok na izlazu nije dobiven željeni izlaz. Jedan od najčešće korištenih algoritama nadziranog učenja je algoritam povratnog rasprostiranja pogreške tokom kojeg se računa razlika između izlaza neuronske mreže i izlaza definiranog kroz skup podataka za učenje. Iterativnim učenjem se težine prilagođavaju s ciljem minimiziranja te razlike. Ovakve tehnike učenja imaju dobar učinak kada se primjenjuju na dobro definirane probleme s unaprijed poznatim željenim rješenjima [20–22].

## **Ne-nadzirano učenje**

Ne-nadzirano učenje pokušava emitirati ljudsku mogućnost samostalnog snalaženja u novim situacijama bez vanjskog učitelja. Uz ne-nadzirano učenje neuronska mreža pokušava samostalno generalizirati ulazne podatke prilagođavanjem svojih težina. Područje ne-nadziranog učenja još nije u potpunosti istraženo, ali pruža uvide u mogućnosti samostalnog učenja [20–22]. Ne-nadzirano učenje postaje temelj za stvaranje samo-organizirajućih neuronskih mreža od kojih je najviše istraživanja usmjereno prema Kohonenovoj samo-organizirajućoj mapi [22].

### **3.2.3. Kohonenova samo-organizirajuća mapa**

Kohonenova samo-organizirajuća mapa (engl. *Self-Organizing Map*, *SOM*) je posebna vrsta umjetne neuronske mreže koja ima samo jedan skriveni sloj, a nema izlazni sloj. Osnovna karakteristika ovakve mreže je međusobna povezanost neurona skrivenog sloja. Prema [23] ovakva vrsta neuronske mreže pokušava topološki imitirati ljudski mozak za koji je uočeno da organizira neurone u grupe sa sličnim namjenama. SOM se nekad naziva topološkom mapom jer težine neurona mogu predstavljati prostorne koordinate. Model SOM-a s 25 neurona skrivenog sloja prikazan je na slici 9.



Slika 9: SOM model s 25 neurona skrivenog sloja i  $n_I$  neurona ulaznog sloja

S obzirom na to da SOM nema izlazni sloj ona na osnovu ulaznog vektora  $X$  daje rezultat u obliku pobjedničkog neurona. Pobjednički neuron je onaj neuron čije težine najviše odgovaraju ulaznom vektoru  $X$ . Ako je  $X$  uređena  $n$ -torka realnih brojeva  $X = (x_1, x_2, x_3, \dots, x_n)$  koja predstavlja ulazni signal moguće je odrediti vektorski prostor kao skup  $\mathbb{R}^n$  kojeg čine sve uređene  $n$ -torke  $(x_1, x_2, x_3, \dots, x_n)$  [24]. S obzirom na to da su u SOM-u težine pojedinog neurona  $W = (w_1, w_2, w_3, \dots, w_n)$  također uređene  $n$ -torke moguće je vektor težina pojedinog neurona prikazati kao točku unutar definiranog prostora  $\mathbb{R}^n$ . Tada će za ulazni vektor  $X$  pobjednički neuron biti onaj neuron za kojeg izraz 9 ima najmanju vrijednost [25].

$$d(X, W_j) = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2} \quad (9)$$

Učenje SOM-a se provodi kroz ne-nadzirano učenje. Za učenje je potrebno pripremiti skup ulaznih vektora koji se iterativno šalju ulaznom sloju mreže. Za svaki ulazni vektor se računa pobjednički neuron čije težine se tada prilagođavaju tako da više odgovaraju ulaznom vektoru.

Nakon prilagodbe pobjedničkog neurona podešavaju se težine susjednih neurona, ali uz nešto manji koeficijent promjene. Što je susjedni neuron bliži pobjedničkom neuronu njegove težine se više primiču pobjedničkom. Matematički se učenje odnosno podešavanje težina neurona može izraziti izrazima [26]:

$$W(t+1) = W(t) + \Theta(t)L(t)(X(t) - W(t)) \quad t = 1, 2, 3, \dots, \quad (10)$$

$$\Theta(t) = \exp\left(-\frac{dist^2}{2\sigma^2(t)}\right), \quad (11)$$

$$\sigma(t) = \sigma_0 \exp\left(-\frac{t}{\lambda}\right), \quad (12)$$

$$L(t) = L_0 \exp\left(-\frac{t}{\lambda}\right), \quad (13)$$

gdje je:

$t$  - vremenski korak/iteracija;

$W(t)$  - vektor težina neurona za vremenski korak  $t$ ;

$X(t)$  - ulazni vektor za vremenski korak  $t$ ;

$\Theta(t)$  - koeficijent udaljenosti neurona od pobjedničkog neurona;

$L(t)$  - funkcija stope učenja za vremenski korak  $t$ ;

$dist$  - udaljenost neurona od pobjedničkog neurona;

$\sigma(t)$  - širina susjedstva pobjedničkog neurona za vremenski korak  $t$ ;

$\sigma_0$  - širina susjedstva za vremenski korak  $t_0$ ;

$\lambda$  - vremenska konstanta;

$L_0$  - stopa učenja za vremenski korak  $t_0$ .

### 3.2.4. Algoritmi ojačanog učenja

Ojačano učenje je grana strojnog učenja koja proučava sustave koji su sposobni učiti iz iskustva prikupljenog tijekom njihova rada. Osnova ojačanog učenja je sposobnost sustava, odnosno agenta da utječe na svoju okolinu. Takvu okolinu se opisuje Markovljevim procesom odlučivanja koji definira skup stanja i akcija koje agent može izvršiti [27]. Izvršavajući akcije nad okolinom agent prima povratnu informaciju u obliku nagrade. Cilj agenta tada postaje maksimizirati dobivenu nagradu, odnosno izgraditi optimalni zakon odabira akcija (engl. *policy*) kontinuiranim praćenjem dobivene nagrade nakon svake poduzete akcije [27, 28].

Kako bi se ojačano učenje moglo primijeniti za upravljanje semaforiziranim raskrižjem potrebno je definirati skup stanja  $S$  i skup akcija  $A$  za zadano raskrižje. Skup stanja se može odrediti prema mjerenim prometnim parametrima na raskrižju. Za opisivanje trenutnog stanja raskrižja dobar pokazatelj su duljine repova čekanja na pojedinim prilazima raskrižju. Skup akcija može biti određen kao skup izmjena postojećeg signalnog plana ili skup potpuno novih signalnih planova. Nakon određivanja svih stanja i akcija određuje se takozvana  $Q$ -matrica:

$$Q = \begin{matrix} & a_1 & a_2 & a_3 & \cdots & a_j \\ \begin{matrix} s_1 \\ s_2 \\ s_3 \\ \vdots \\ s_i \end{matrix} & \begin{bmatrix} q_{1,1} & q_{1,2} & q_{1,3} & \cdots & q_{1,j} \\ q_{2,1} & q_{2,2} & q_{2,3} & \cdots & q_{2,j} \\ q_{3,1} & q_{3,2} & q_{3,3} & \cdots & q_{3,j} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ q_{i,1} & q_{i,2} & q_{i,3} & \cdots & q_{i,j} \end{bmatrix} \end{matrix},$$

gdje je:

$i$  - broj definiranih stanja skupa  $S$ ;

$j$  - broj definiranih akcija skupa  $A$ .

Prije učenja svi elementi  $Q$  matrice su postavljeni na 0, te će se vrijednosti pojedinih elemenata mijenjati u ovisnosti o dobivenoj nagradi za poduzetu akciju  $a$  nad stanjem  $s$ .

## Algoritam SARSA

Algoritam SARSA (engl. *State-Action-Reward-State-Action*) je algoritam ojačanog učenja koji pokušava odrediti optimalni zakon upravljanja koristeći interakciju s okolinom i osvježavajući vrijednosti Q matrice prema pravilu [27, 28]:

$$Q(S_t, A_t) \leftarrow Q(S_t, A_t) + \alpha [R_{t+1} + \gamma Q(S_{t+1}, A_{t+1}) - Q(S_t, A_t)], \quad (14)$$

gdje je:

$t$  - vremenski korak/iteracija;

$\alpha$  - koeficijent učenja;

$R$  - nagrada;

$\gamma$  - faktor odgode nagrade.

Rad SARSA algoritma prikazan je pseudokôdom 1:

---

### Pseudokôd 1 SARSA [28]

---

Inicijaliziraj  $Q(s, a)$ ,  $\forall (s \in S, a \in A)$ ;

Ponavljaj (za svaku epizodu učenja):

    Inicijaliziraj  $S$ ;

    Odaberi  $a$  iz skupa akcija  $A$  prema zakonu odabira;

    Ponavljaj (za svaki korak učenja):

        Poduzmi  $a$ , dohvati nagradu  $R$  i stanje  $s'$ ;

        Odaberi  $a'$  iz skupa  $A$  prema zakonu odabira;

$Q(s, a) \leftarrow Q(s, a) + \alpha [R + \gamma Q(s', a') - Q(s, a)]$ ;

$s \leftarrow s'$ ;  $a \leftarrow a'$ ;

---

Odabir akcije iz skupa akcija  $A$  se vrši prema definiranom zakonu odabira. Najčešće se koriste takozvani pohlepni algoritam (engl. *greedy algorithm*) i  $\varepsilon$  - pohlepni algoritam. Pohlepni algoritam uvijek odabire akciju za koju je trenutno utvrđena najveća kumulativna nagrada.  $\varepsilon$  - pohlepni algoritam generira nasumičan broj te ako je taj generirani broj veći od unaprijed definiranog parametra  $\varepsilon$  algoritam odabire akciju na isti način kao pohlepni algoritam. Ako je generirani broj manji od parametra  $\varepsilon$  onda se odabire nasumična akcija. Iznos dobivene nagrade  $R$  ovisi o mjerljivim parametrima uspješnosti izvršene akcije. Za potrebe upravljanja raskrižjem, kao nagrada se može koristiti razlika između iznosa duljine prijašnjeg i trenutnog reda čekanja



ili bilo kojeg drugog mjerljivog prometnog parametra. To može biti propusnost raskrižja, razina usluznosti, broj zaustavljanja itd.

### Algoritam Q-učenja

Q-učenje kao algoritam ojačanog učenja radi na sličnom principu kao SARSA algoritam s jedinom razlikom u pravilu osvježavanja Q matrice. Prilikom dodavanja odgođene nagrade Q-učenje pohlepno uzima vrijednost Q matrice za onu akciju koja za novo stanje ima najveću kumulativnu nagradu, iako ta akcija možda neće biti odabrana u sljedećoj iteraciji učenja. Pravilo osvježavanja Q matrice korištenjem algoritma Q-učenja prikazano je izrazom 15:

$$Q(S_t, A_t) \leftarrow Q(S_t, A_t) + \alpha \left[ R_{t+1} + \gamma \max_a Q(S_{t+1}, a) - Q(S_t, A_t) \right]. \quad (15)$$

Rad algoritma Q-učenja prikazan je pseudokôdom 2:

---

#### Pseudokôd 2 Q-učenje [28]

---

Inicijaliziraj  $Q(s, a)$ ,  $\forall (s \in S, a \in A)$ ;

Ponavljaj (za svaku epizodu učenja):

Inicijaliziraj  $S$ ;

Odaberi  $a$  iz skupa akcija  $A$  prema zakonu odabira;

Ponavljaj (za svaki korak učenja):

Poduzmi  $a$ , dohvati nagradu  $R$  i stanje  $s'$ ;

$Q(s, a) \leftarrow Q(s, a) + \alpha \left[ R + \gamma \max_A Q(s', A) - Q(s, a) \right]$ ;

$s \leftarrow s'$ ;

---

Kod svakog algoritma ojačanog učenja teži se konvergenciji Q matrice. Konvergencija u ovom smislu označava izgrađeni optimalni zakon odabira akcija  $A$  za svako stanje  $S$ . Prema [29] Q-učenje konvergira ako se svaki par akcija i stanja posjeti dovoljan broj puta, pri čemu je kod složenijih sustava potreban veći broj posjeta. Iako matematički Q učenje konvergira dok vremenski korak  $t$  teži u beskonačnost za primjenu u stvarnim sustavima potrebno je osigurati približnu konvergenciju u stvarnom vremenu. Na brzinu konvergencije mogu utjecati parametri  $\alpha$ ,  $\gamma$ ,  $\epsilon$ , ali najznačajniji utjecaj ima broj stanja i akcija za koje se traži optimalni zakon. Što je broj stanja i akcija veći algoritmu će biti potrebno više iteracija učenja za konvergenciju. Ovaj problem postaje naročito izražen u sustavima s ne-diskretnim stanjima, pa je potrebno koristiti različite tehnike određivanja stanja poput korištenja aproksimacijske funkcije, kôdiranja s poljima (engl. *tile*) i grubog (engl. *coarse*) kôdiranja [30]. U nastavku je prikazan prijedlog

sustava upravljanja izoliranim semaforiziranim raskrižjem zasnovan na Q-učenju s korištenjem Kohonenove SOM mreže za generalizaciju stanja prometa na raskrižju.

### **3.3. Inteligentno upravljanje semaforiziranim raskrižjem**

Problem upravljanja semaforiziranim raskrižjem je moguće riješiti primjenom tehnika umjetne inteligencije. Kao što je opisano u prethodnom poglavlju problemu je moguće pristupiti pasivnom, aktivnom ili adaptivnom strategijom.

#### **Pasivno upravljanje**

U pasivnom pristupu umjetna inteligencija se može koristiti u sklopu ekspertnog sustava za generiranje signalnog plana raskrižja. Takav sustav bi trebao sadržavati znanje prometnog inženjera usmjereno prema izračunu propusne moći semaforiziranog raskrižja. Činjenice koje bi se unosile u takav sustav su podaci o prometnom opterećenju pojedinog privoza raskrižju u obliku izvorišno-odredišne matrice te podaci o geometriji raskrižja. Sustav tada izračunom daje optimalno rješenje u obliku signalnog plana. Ako se istovremeno računaju signalni planovi za velik broj povezanih raskrižja dolazi do poteškoća pri izračunu optimalnog rješenja, pa je moguće iskoristiti genetski algoritam za izračun dovoljno dobrog rješenja.

#### **Aktivno upravljanje**

Aktivno upravljanje se odnosi na korištenje trenutnih podataka prikupljenih s višestrukih osjetila. Osjetila u ovom kontekstu prikupljaju podatke o trenutnom prometnom opterećenju raskrižja i time upotpunjuju bazu podataka u obliku činjenica. Mehanizam zaključivanja zatim koristi bazu podataka i bazu znanja kako bi odredio izmjene signalnog plana. Takvo zaključivanje može koristiti neizrastu logiku i neizrastita pravila za donošenje odluka [5, 6].

#### **Adaptivno upravljanje**

Adaptivno upravljanje se može opisati i kao upravljanje prema trenutnim podacima zasnovano na iskustvu. Za pojašnjenje ovog koncepta može se zamisliti ručno upravljanje raskrižjem. Prometni službenik prikuplja podatke o stanju na raskrižju i donosi odluke o upravljanju prema definiranim pravilima. S vremenom službenik može evaluirati donošene odluke i time prikupiti iskustvo s kojim može nadograditi svoje znanje. S umjetnim adaptivnim upravljanjem cilj je

postići takvu razinu učenja emulirajući prometnog službenika. Takav sustav zasnovan na učenju je prikazan u idućem poglavlju.

## 4. Adaptacija signalnog plana pomoću neuronske mreže

Adaptacija signalnog plana se može odrediti kao problem odabira optimalnog signalnog plana za trenutnu prometnu situaciju. Moguće je korištenjem ekspertnih sustava aktivno računati novi signalni plan prikupljanjem podataka na raskrižju, ali se zbog teške prilagodbe metodologije izračuna i stohastične prirode prometa teško dolazi do optimalnog rješenja bez adaptivnog učenja. Kroz učenje sustav može naučiti koji signalni plan najbolje odgovara pojedinom stanju u prometu. Problem koji se tada pojavljuje je diskretizacija prostora stanja prometne mreže. Ako se primjerice prikupljaju podaci o redu čekanja na  $n$  privoza raskrižju postavlja se pitanje na koliko razreda treba podijeliti te podatke. Podjelom na  $k$  razreda dobiva se  $k^n$  mogućih diskretnih stanja sustava. Zbog eksponencijalnog rasta dodavanjem novih razreda ili mjernih osjetila broj stanja za koje treba odrediti optimalni signalni plan brzo postaje prevelik. Pri tome je moguće očekivati da isti signalni plan može biti optimalan za više sličnih stanja prometne mreže. Kako bi se riješio problem diskretizacije stanja u nastavku je predložena metoda određivanja stanja prometne mreže uz korištenje neuronske mreže.

### 4.1. Određivanje stanja prometne mreže

U prometu se stanje prometne mreže na raskrižju može opisati kroz velik broj prometnih parametara, primjerice moguće je pratiti duljine redova čekanja za svaku prometnu traku koja prilazi raskrižju, prosječne brzine vozila, kategorije vozila, itd. Kombinacijom mjerenih prometnih parametara dobiva se prostor mogućih stanja  $\mathbb{R}^n$  gdje je  $n$  broj mjerenih parametara. Svaku točku u tom prostoru može se promatrati kao jedno stanje prometne mreže. Mapiranjem velikog broja stanja u prostor  $\mathbb{R}^n$  može se primijetiti da točke čija je međusobna udaljenost mala pokazuju slične karakteristike, dok točke s velikom međusobnom udaljenosti imaju vrlo različite karakteristike. Cilj određivanja stanja prometne mreže je podijeliti prostor  $\mathbb{R}^n$  na potprostore unutar kojih se nalaze stanja prometa sa sličnim karakteristikama.


Za mali broj mjerenih parametara prostor stanja se može lako podijeliti na pravilne dijelove dijeljenjem svakog mjerenog parametra u razrede jednakih veličina. Nedostatak ovog pristupa je pri primjeni na velik broj mjerenih parametara jer broj definiranih potprostora eksponencijalno raste, te je povećana vjerojatnost da neki tako definirani potprostori u sebi nemaju niti jedno izmjereno stanje. Za rješenje problema se može iskoristiti SOM mreža koja će generalizirati skup izmjerenih podataka i time izgraditi topologiju sličnu ulaznim podacima. Nakon što je neuronska mreža trenirana, svaki od neurona će oko sebe definirati područje unutar kojeg je on pobjednički neuron. Stanje prometne mreže se zatim identificira s rednim brojem pobjedničkog neurona. Ovim pristupom se može smanjiti broj dimenzija mjerenih prometnih parametara.

Fleksibilnost ovog pristupa omogućuje da se broj stanja koje se želi identificirati odredi prilikom definiranja strukture SOM mreže gdje će broj neurona skrivenog sloja biti jednak broju identificiranih stanja. Ovakvom generalizacijom prostora stanja moguće je znatno ubrzati procese ojačanog učenja za upravljanje raskrižjem.

## **4.2. Algoritam ojačanog učenja zasnovan na neuronskoj mreži**

Algoritmi ojačanog učenja samostalno grade bazu znanja promatrajući stanje sustava i poduzimajući akcije. Nakon svake poduzete akcije algoritam evaluira postignuti rezultat. Učenje se ponavlja iterativno dok se za svako stanje sustava ne odredi optimalna akcija. U ovom potpoglavlju dan je opis primjene neuronske mreže za smanjivanje broja stanja kod algoritma ojačanog učenja.

Kako bi se izbjegao problem visokog broja dimenzija pri određivanju stanja prometnog sustava te eksponencijalnog porasta veličine  $Q$ -matrice moguće je koristiti SOM mrežu koja će provoditi generalizaciju prometnih parametara i tako odrediti stanja prometne mreže. Takvo procjenjivanje stanja se može koristiti u suradnji s algoritmom  $Q$  učenja. Struktura takvog sustava prikazana je na slici 10. S obzirom na to da brzina konvergencije ovisi o broja stanja i akcija, moguće je odabrati broj stanja koja će se analizirati prilikom stvaranja SOM mreže, gdje će broj stanja biti jednak broju neurona skrivenog sloja, a broj promatranih parametara će biti jednak broju neurona ulaznog sloja [31–33].



Slika 10: Sustav za upravljanje raskrižjem korištenjem Q-učenja zasnovan na neuronskoj mreži

Primjenu navedenog sustava je potrebno obaviti u dvije faze. U prvoj fazi se prikupljaju prometni parametri s raskrižja, te se na temelju njih uči SOM mreža. Kada je završeno učenje SOM mreže ona se stavlja u pasivno stanje u kojem više neće podešavati težine neurona. U drugoj fazi se sustavu priključuje agent Q učenja, te se zatim provodi njegovo učenje. Prema [27, 28] rad agenta Q učenja se može podijeliti na istraživanje i eksploataciju stečenog znanja. Istraživanjem se smatra odabir nasumičnih akcija, dok eksploatacija predstavlja korištenje akcije za koju je trenutno utvrđena najveća kumulativna nagrada u Q matrici. Omjer istraživanja i eksploatacije se može odrediti korištenjem  $\epsilon$  - pohlepnog zakona za odabir akcije. Podešavanjem parametra  $\epsilon$  moguće je u početku rada sustava uglavnom birati nasumične akcije kako bi agent prikupio što veću količinu znanja, u kasnijim iteracijama rada  $\epsilon$  prilazi nuli što dovodi do iskorištavanja stečenog znanja jer će uglavnom biti odabrana akcija s najvećom kumulativnom nagradom. Dobra je praksa držati parametar  $\epsilon$  trajno na vrijednosti malo iznad nule kako bi sustav s vremenom ponovno pokušao primijeniti nasumičnu akciju, što omogućuje sustavu da se trajno prilagođava stanju prometne mreže. To je naročito bitno u slučajevima kada korisnici prometne mreže mijenjaju svoje ponašanje ili se pojavi nepoznato stanje prometa za koje je tek potrebno pronaći novi optimalni upravljački zakon.

## 5. Simulacijsko okruženje PTV VISSIM/AForge

Sustav upravljanja prometom zasnovan na učenju je teško razvijati direktnom primjenom u prometnom sustavu zbog dugog procesa učenja tijekom kojeg sustav može negativno djelovati na rad prometnog sustava. Kao rješenje problema moguće je koristiti simulacijske alate za simuliranje prometnog sustava, te provesti početno učenje sustava u simulacijskom okruženju. Kako bi simulacija što više odgovarala stvarnoj situaciji potrebno je provesti detaljno umjeravanje simulacije. Jedan od često korištenih alata je mikroskopski simulator VISSIM tvrtke PTV [11]. Iako je korištenjem alata VISSIM moguće simulirati rad prometnog sustava u njemu nije moguće izraditi sustave upravljanja zasnovane na učenju, već je za to potrebno koristiti vanjske aplikacije. VISSIM omogućuje vanjskim aplikacijama pristup objektima simulacije kroz COM sučelje, pa je moguć paralelni rad simulatora VISSIM i vanjske aplikacije s ugrađenim algoritmom upravljanja odnosno učenja. Pri izradi vanjskih aplikacija moguće je koristiti različite biblioteke (engl. *library*) za izradu sustava zasnovanih na umjetnoj inteligenciji. Jedna takva biblioteka otvorenog kôda je AForge.NET framework [12]. Objedinjavanjem simulatora PTV VISSIM i vanjske aplikacije s bibliotekom AForge moguće je stvoriti simulacijsko okruženje za razvoj i testiranje sustava upravljanja prometom zasnovanih na metodama umjetne inteligencije.


### 5.1. Simulacijski alat PTV VISSIM

Mikroskopski simulator VISSIM tvrtke PTV je aplikacija za analiziranje, simulaciju i optimizaciju prometnih tokova. Pojam mikroskopske simulacije označava simulaciju u kojoj se svaki prometni entitet (pješač, automobil, tramvaj, itd.) simulira individualno u jednom modelu. Za razliku od mikroskopske simulacije makroskopska prometne tokove promatra kao cjelinu. Postoje još i mezoskopske simulacije koje rade kombiniranjem tehnika mikroskopskih i makroskopskih simulacija. VISSIM simulator se sastoji od sedam jezgrenih modula [2, 8, 19]:

1. **Modul generiranja nasumičnih brojeva:** generira nasumične brojeve za određivanje stohastičnih elemenata simulacije;
2. **Modul atributa vozila i vozača:** definira attribute i karakteristike vozila te vozača koji

ulaze u prometnu mrežu;

3. **Modul generiranja vozila:** definira kada i gdje će pojedino vozilo ući u prometnu mrežu;
4. **Modul praćenje vozila:** definira ponašanje vozila u ovisnosti o drugim vozilima;
5. **Modul mijenjanja prometne trake:** Definira načine promjene prometne trake vozila;
6. **Modul signalnog uređaja:** definira upravljanje signalnim uređajima u prometnoj mreži;
7. **Modul animacije:** prikazuje animaciju vozila u simuliranoj prometnoj mreži, rad animacijskog modula prikazan je na slici 11.



Slika 11: Prikaz rada modula animacije simulatora VISSIM

## 5.2. Biblioteka za metode umjetne inteligencije AForge

Biblioteka AForge.NET framework je biblioteka otvorenog kôda pisana za programski jezik C# namijenjena razvoju i istraživanju unutar polja računalnog vida i umjetne inteligencije [12]. Biblioteka omogućava jednostavno integriranje modula računalnog vida i umjetne inteligencije u postojeće C# projekte pozivanjem na jedan od sljedećih imeničkih prostora:

**AForge.Fuzzy** - sadrži klase i sučelja za rad s neizrazitim sustavima;

**AForge.Genetic** - sadrži klase i sučelja za rješavanje problema uz korištenje genetskog algoritma;

**AForge.Imaging** - sadrži klase i sučelja za obradu slike;

**AForge.MachineLearning** - sadrži klase i sučelja za algoritme strojnog učenja;



**AForge.Math** - sadrži klase za rješavanje matematičkih problema korištene u drugim AForge modulima;

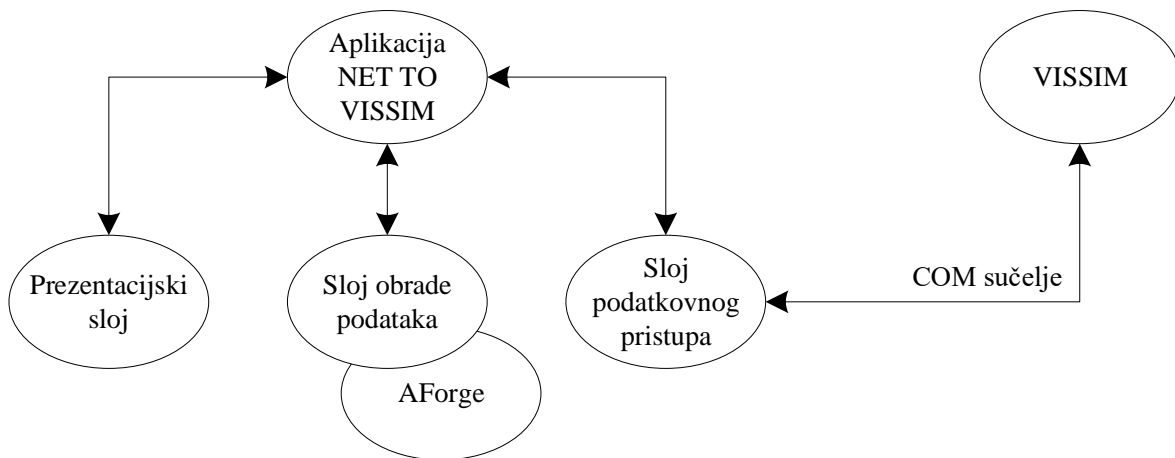
**AForge.Neuro** - sadrži klase i sučelja za izradu i učenje neuronskih mreža;

**AForge.Robotics** - sadrži klase i sučelja za upravljanje određenim komponentama robotskih sustava;

**AForge.Video** - sadrži klase i sučelja za obradu video zapisa.

### 5.3. Simulacijsko okruženje NET TO VISSIM

Kako bi se uspješno mogli razvijati i testirati različiti algoritmi umjetne inteligencije u prometu potrebno je izgraditi simulacijsko okruženje koje se sastoji od simulatora prometa i upravljačke aplikacije za primjenu umjetne inteligencije. Poštujući VISSIM hijerarhiju objekata moguće je pristupiti i upravljati objektima simulacije kroz izgrađeno simulacijsko okruženje [2]. Jedno takvo okruženje je projekt u nastajanju NET TO VISSIM [34]. Okruženje komunicira s VISSIM objektima korištenjem COM sučelja prema modelu prikazanom na slici 12. Ciljevi projekta su uspostavljanje komunikacije s VISSIM objektima, prikupljanje prometnih podataka iz VISSIM simulacije, upravljanje signalizacijom, implementacija tehnika umjetne inteligencije uz korisničko sučelje za jednostavno upravljanje i praćenje rada. Za primjenu tehnika umjetne inteligencije okruženje koristi biblioteku AForge.




Slika 12: Simulacijsko okruženje NET TO VISSIM

## 6. Simulacijski rezultati

U ovom poglavlju opisan je korišteni model semaforiziranog raskrižja, te dobiveni simulacijski rezultati nakon implementacije algoritma za upravljanje zasnovanog na SOM neuronskoj mreži i Q-učenju.

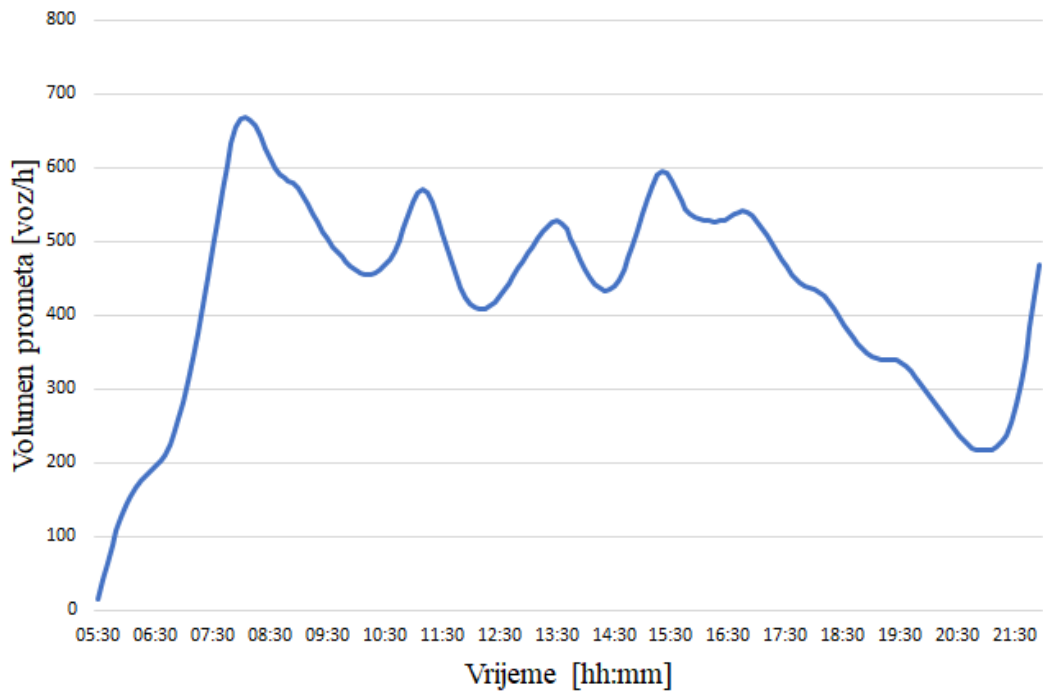
### 6.1. Opis modela korištenog semaforiziranog raskrižja

Za potrebe razvoja i testiranja upravljačkog algoritma u VISSIM-u je izgrađen model izoliranog semaforiziranog raskrižja po uzoru na stvarno raskrižje: "Ulica kralja Zvonimira - Ulica Vjekoslava Heinzela" prema podacima iz [2] [7]. Slika 13 prikazuje VISSIM model izoliranog raskrižja.

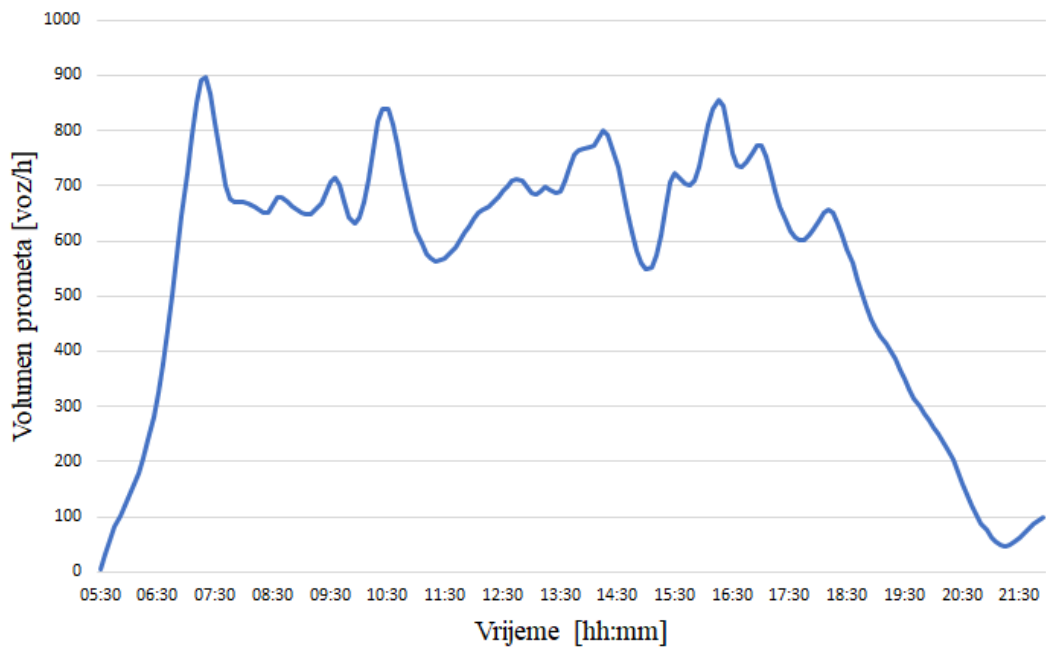


Slika 13: VISSIM model izoliranog raskrižja: Ulica kralja Zvonimira - Ulica Vjekoslava Heinzela


Kako bi algoritam mogao učiti iz više različitih prometnih situacija model je proširen da obuhvaća razdoblje od 05:30 do 22:00 sati. Prometna potražnja je generirana korištenjem podataka o profilima brzina iz [35] u kombinaciji s podacima iz [7] i ručnim mjerenjima. Pješачki promet nije postavljen u simulaciju zbog nedostatka istraživanja o ponašanju pješaka u prometu, ali je pri izračunu signalnih planova uračunato zaštitno vrijeme prolaska pješaka kroz prometnicu. Generirana prometna potražnja prikazana je grafikonima 1, 2, 3 i 4.




Grafikon 1: Generirana prometna potražnja: Ulica Vjekoslava Heinzela sjever



Grafikon 2: Generirana prometna potražnja: Ulica Vjekoslava Heinzela jug




Grafikon 3: Generirana prometna potražnja: Ulica kralja Zvonimira - istok



Grafikon 4: Generirana prometna potražnja: Ulica kralja Zvonimira - zapad

Osnovni ustaljeni signalni plan raskrižja prikazan je na slici 14 [7]. Za potrebe evaluacije algoritma rezultati su uspoređivani s rezultatima dobivenim simulacijom korištenjem samo ustaljenog signalnog plana.



Slika 14: Ustaljeni signalni plan: Ulica kralja Zvonimira - Ulica Vjekoslava Heinzela [7]

## 6.2. Postavke SOM mreže i Q-učenja

U ovom potpoglavlju su opisani parametri SOM mreže i Q-učenja korišteni pri simulaciji upravljanja raskrižjem.

### 6.2.1. Postavke SOM mreže

Kako bi se mogla učiti SOM mreža generirani su prometni podaci simulacijom raskrižja s ustaljenim signalnim planom. Prikupljeno je 18 parametara u pet-minutnim intervalima mjerenja:

1.  $x_1$  - Prosječan broj vozila u redu čekanja za istočni prilaz, prometna traka za lijevo skretanje;
2.  $x_2$  - Prosječan broj vozila u redu čekanja za istočni prilaz, prometne trake za ravno i desno skretanje;
3.  $x_3$  - Prosječan broj vozila u redu čekanja za sjeverni prilaz, prometna traka za lijevo skretanje;
4.  $x_4$  - Prosječan broj vozila u redu čekanja za sjeverni prilaz, prometne trake za ravno i desno skretanje;

5.  $x_5$  - Prosječan broj vozila u redu čekanja za zapadni prilaz, prometna traka za lijevo skretanje;
6.  $x_6$  - Prosječan broj vozila u redu čekanja za zapadni prilaz, prometne trake za ravno i desno skretanje;
7.  $x_7$  - Prosječan broj vozila u redu čekanja za južni prilaz, prometna traka za lijevo skretanje;
8.  $x_8$  - Prosječan broj vozila u redu čekanja za južni prilaz, prometne trake za ravno;
9.  $x_9$  - Prosječan broj vozila u redu čekanja za južni prilaz, prometna traka za desno skretanje;
10.  $x_{10}$  - Maksimalni broj vozila u redu čekanja za istočni prilaz, prometna traka za lijevo skretanje;
11.  $x_{11}$  - Maksimalni broj vozila u redu čekanja za istočni prilaz, prometne trake za ravno i desno skretanje;
12.  $x_{12}$  - Maksimalni broj vozila u redu čekanja za sjeverni prilaz, prometna traka za lijevo skretanje;
13.  $x_{13}$  - Maksimalni broj vozila u redu čekanja za sjeverni prilaz, prometne trake za ravno i desno skretanje;
14.  $x_{14}$  - Maksimalni broj vozila u redu čekanja za zapadni prilaz, prometna traka za lijevo skretanje;
15.  $x_{15}$  - Maksimalni broj vozila u redu čekanja za zapadni prilaz, prometne trake za ravno i desno skretanje;
16.  $x_{16}$  - Maksimalni broj vozila u redu čekanja za južni prilaz, prometna traka za lijevo skretanje;
17.  $x_{17}$  - Maksimalni broj vozila u redu čekanja za južni prilaz, prometne trake za ravno;
18.  $x_{18}$  - Maksimalni broj vozila u redu čekanja za južni prilaz, prometna traka za desno skretanje

S obzirom na to da je prikupljeno 18 različitih prometnih parametara zadatak SOM mreže postaje generalizirati prostor  $\mathbb{R}^{18}$  na diskretni broj stanja. Pri tome je ideja naći najmanji broj


prometnih stanja koji dobro opisuje ponašanje analiziranog izoliranog raskrižja. Rad sustava će se analizirati u tri scenarija s različitim brojem određenih stanja, odnosno različitim brojem neurona skrivenog sloja SOM mreže. Za svaki od scenarija korišteni su parametri SOM učenja prikazani u tablici 1

Tablica 1: Parametri učenja SOM mreže

Parametar	Vrijednost
$L_0$	0,5
$\sigma_0$	3

### Scenarij 1

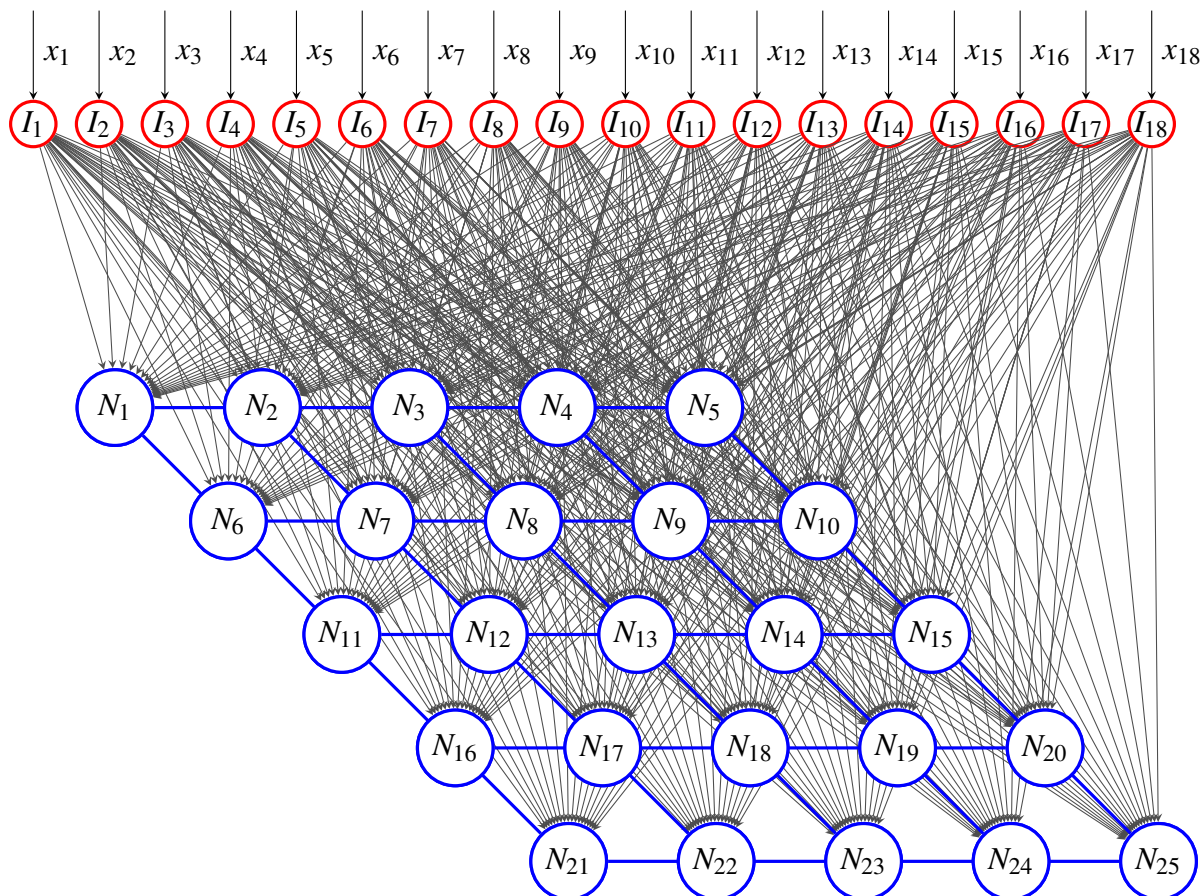
U prvom scenariju prostor stanja prometnog sustava je generaliziran na 16 stanja korištenjem SOM mreže sa strukturom prikazanoj na slici 15.



Slika 15: SOM mreža s 18 neurona ulaznog sloja i 16 neurona skrivenog sloja

### Scenarij 2

U drugom scenariju prostor stanja prometnog sustava je generaliziran na 25 stanja korištenjem SOM mreže sa strukturom prikazanoj na slici 16.




Slika 16: SOM mreža s 18 neurona ulaznog sloja i 25 neurona skrivenog sloja

### Scenarij 3

U trećem scenariju prostor stanja prometnog sustava je generaliziran na 484 stanja korištenjem SOM mreže sa strukturom prikazanoj na slici 17.







Slika 17: SOM mreža s 18 neurona ulaznog sloja i 484 neurona skrivenog sloja

### 6.2.2. Postavke Q-učenja


Neovisno o broju stanja dobivenih iz SOM mreže skup akcija je isti za svaki analizirani scenarij i sastoji se od skupa definiranih signalnih planova. Definirani signalni planovi prikazani su slici 18. Signalni planovi definirani akcijama su zasnovani na ustaljenom signalnom planu s manjim izmjenama kako bi se izbjeglo zbunjivanje sudionika u prometu zbog tendencije ponašanja prema navici [7]. Problem zbunjivanja sudionika u prometu je osobito istaknut u sustavima s promjenom redoslijeda faza zbog visoke mogućnosti naleta vozila iz konfliktnog smjera. Iz tog razloga u ovom radu nije korištena izmjena redoslijeda faza.




(a) Akcija 1




(b) Akcija 2




(c) Akcija 3




(d) Akcija 4



(e) Akcija 5



(f) Akcija 6



(g) Akcija 7

Slika 18: Signalni planovi odnosno akcije za upravljanje

Za svaki scenarij korišteni su parametri Q-učenja prikazani u tablici 2.

Tablica 2: Parametri Q-učenja

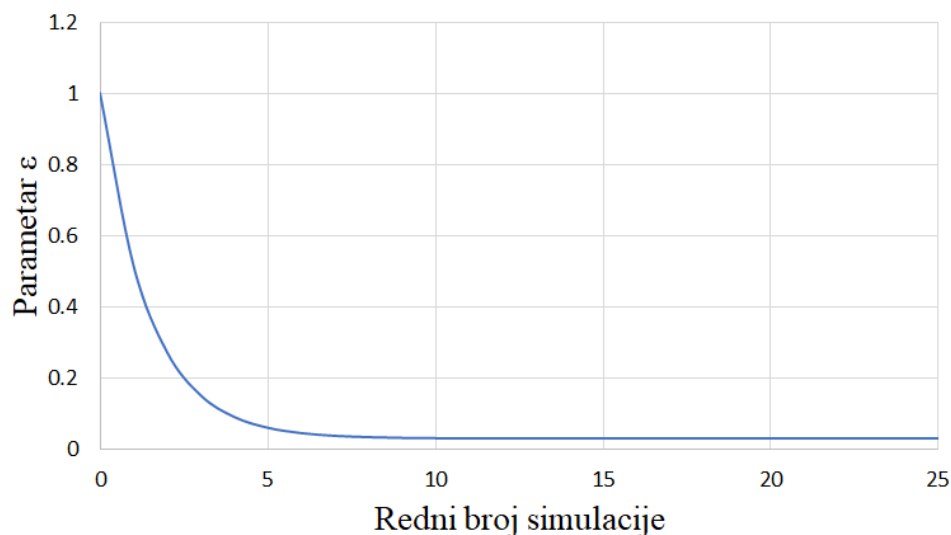
Parametar	Vrijednost
$\alpha$	0,25
$\gamma$	0,1

Za odabir akcije korišten je  $\varepsilon$  - pohlepni algoritam s promjenjivim parametrom  $\varepsilon$  prema izrazu 16 prikazanog grafikonom 5.

$$\varepsilon = 0,97 \cdot 0,5^{i-1} + 0,03, \quad (16)$$

gdje je:

$i$  - Redni broj simulacije.



Grafikon 5: Promjena parametra  $\varepsilon$  u ovisnosti o rednom broju simulacije

Nagrada kao parametar funkcije osvježavanja Q tablice je jednaka razlici izgubljenog vremena vozila prije poduzete akcije i nakon poduzete akcije. Ako je izgubljeno vrijeme vozila prije poduzete akcije veće od izgubljenog vremena nakon poduzete akcije nagrada će biti pozitivna, a njen iznos će ovisiti o postignutom poboljšanju. Nagrada se može prikazati izrazom:

$$R_{t+1} = D_t - D_{t+1}, \quad (17)$$

gdje je:

$D_t$  - izgubljeno vrijeme svih vozila prije poduzimanja akcije;

$D_{t+1}$  - izgubljeno vrijeme nakon poduzimanja akcije.

### 6.3. Prikaz i analiza rezultata simulacije

Kako bi se mogao analizirati rad predloženog sustava za svaki scenarij je simulirano 100 simulacija s postavkama prikazanim u tablici 3. Za svaki zadani scenarij prikupljeni su sljedeći prometni parametri:

$TT_{TOT}$  - Ukupno vrijeme putovanja svih vozila [s];

$LT_{AVG}$  - Prosječno izgubljeno vrijeme po vozilu [s/voz];

$ST_{TOT}$  - Ukupno vrijeme zaustavljanja svih vozila [s];

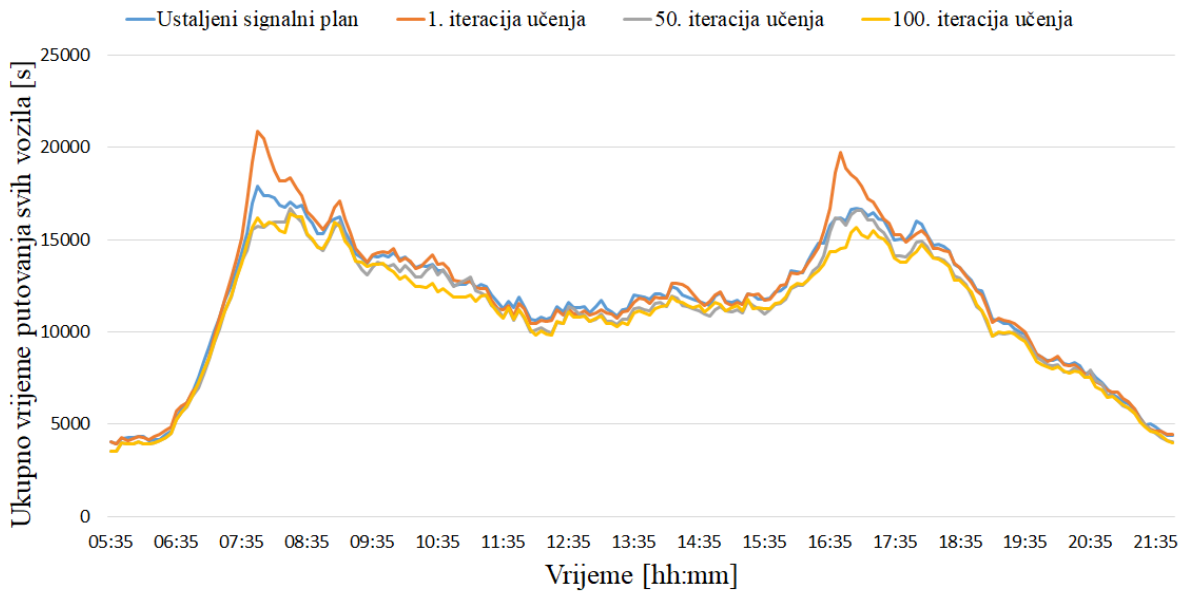
$NS_{TOT}$  - Ukupni broj zaustavljanja svih vozila.

Tablica 3: Simulacijske postavke prema scenarijima

Parametar	Scenarij 1	Scenarij 2	Scenarij 3
Trajanje simulacije [s]	59400	59400	59400
Rezolucija simulacije [korak/s]	1	1	1
Nasumično sjeme	42	42	42
Model slijedenja vozila	Wiedmann 74	Wiedmann 74	Wiedmann 74
Broj neurona SOM mreže	16	25	484

#### 6.3.1. Scenarij 1

Rezultati Ukupnog vremena putovanja svih vozila za prvi scenarij su prikazani grafikonom 6. S obzirom da je SOM mreža imala samo 16 neurona nije bio potreban veliki broj iteracija do dolaska u stacionarno stanje. Nakon samo jedne iteracije učenja ukupno vrijeme putovanja je u značajnom porastu, što se može očekivati za početne iteracije učenja zbog pretežno istraživačkog načina rada. Pri tome se akcije slučajno odabiru kako upravljački sustav još ne zna koja je akcija optimalna. Nakon 50 i 100 iteracija učenja vidljiva su poboljšanja ukupnog vremena putovanja za vrijeme jutarnjeg i poslijepodnevnog vršnog sata, dok između 50. i 100. iteracije nema primjetnih razlika, što je vjerojatno posljedica brze konvergencije prije 50. iteracije učenja.



Grafikon 6: Ukupno vrijeme putovanja svih vozila - Scenarij 1

U tablici 4 prikazani su ukupni rezultati prvog scenarija. Nakon 100. iteracije učenja ukupno vrijeme putovanja smanjeno je za 5,65%. Prosječno izgubljeno vrijeme po vozilu je smanjeno za 11,54%. Ukupno vrijeme zaustavljanja svih vozila smanjeno je za 14,09%, dok je broj zaustavljanja svih vozila smanjen za 4,96%.


Tablica 4: Ukupni rezultati prvog scenarija

Parametar	Ustaljeni signalni plan	SOM 16 neurona i Q učenje					
		1. iteracija učenja		50. iteracija učenja		100. iteracija učenja	
		Iznos	Promjena [%]	Iznos	Promjena [%]	Iznos	Promjena [%]
$TT_{TOT}$ [s]	2287484	2326038	1,69%	2185992	-4,44%	2158325	-5,65%
$LT_{AVG}$ [s/voz]	23,11	23,46	1,55%	20,90	-9,55%	20,44	-11,54%
$ST_{TOT}$ [s]	805762	838872	4,11%	716706	-11,05%	692219	-14,09%
$NS_{TOT}$	30112	30885	2,57%	28941	-3,89%	28617	-4,96%

### 6.3.2. Scenarij 2

Rezultati Ukupnog vremena putovanja svih vozila za drugi scenarij su prikazani grafikonom 7. SOM mreža je imala tek 9 neurona više od mreže u prvom scenariju što je uzrokovalo približno iste rezultate uz nešto sporiji prilazak stacionarnom stanju. Grafikon jasno prikazuje veliki porast vremena putovanja u jutarnjem vršnom satu koji se može očekivati prilikom prvih iteracija učenja. Grafikon prikazuje nešto lošije rezultate nakon 100. iteracije u odnosu na rezultate nakon 50. iteracije. Ovakvo ponašanje se pripisuje šumu koji se pojavljuje pri ulasku u stacionarno stanje, gdje su moguće oscilacije rezultata zbog postavljenog  $\epsilon$  parametra koji

nikad ne iznosi nula. Postavljanjem parametra  $\epsilon$  na nula i smanjenjem parametra stope učenja moguće je sustav dovesti u stabilno stanje, što se ne preporučuje jer tada sustav nema mogućnost prilagodbe i daljnjeg učenja.



Grafikon 7: Ukupno vrijeme putovanja svih vozila - Scenarij 2

U tablici 5 prikazani su ukupni rezultati drugog scenarija. Prema svima parametrima rezultati nakon 100 iteracija učenja drugog scenarija su lošiji od rezultata prvog scenarija. Rezultati nakon 50 iteracija učenja pokazuju smanjenje ukupnog trajanja putovanja za 4,54%, smanjenje prosječnog izgubljenog vremena po vozilu za 9,50%, smanjenje ukupnog vremena zaustavljanja za 11,41% i smanjenje ukupnog broja zaustavljanja svih vozila za 3,70%.


Tablica 5: Ukupni rezultati drugog scenarija

Parametar	Ustaljeni signalni plan	SOM 25 neurona i Q učenje					
		1. iteracija učenja		50. iteracija učenja		100. iteracija učenja	
		Iznos	Promjena [%]	Iznos	Promjena [%]	Iznos	Promjena [%]
$TT_{TOT}$ [s]	2287484	2349807	2,72%	2183678	-4,54%	2204793	-3,61%
$LT_{AVG}$ [s/voz]	23,11	23,78	2,90%	20,91	-9,50%	21,30	-7,83%
$ST_{TOT}$ [s]	805762	856449	6,29%	713836	-11,41%	729932	-9,41%
$NS_{TOT}$	30112	31501	4,61%	28997	-3,70%	29639	-1,57%

### 6.3.3. Scenarij 3

Rezultati Ukupnog vremena putovanja svih vozila za treći scenarij su prikazani grafikonom 8. SOM mreža se sastojala od 484 neurona što je značajno usporilo prilazak stacionarnom

stanju u odnosu na prva dva scenarija. Na grafikonu su vidljive tek male razlike između rezultata ustaljenog signalnog plana i rezultata nakon 50 i 100 iteracija učenja. Ovaj rezultat se pripisuje velikom broju stanja za koja je potrebno naučiti optimalni zakon odabira akcija.



Grafikon 8: Ukupno vrijeme putovanja svih vozila - Scenarij 3

Ukupni rezultati trećeg scenarija prikazani su u tablici 6. Nakon 100 iteracija učenja ukupno vrijeme putovanja svih vozila smanjeno je za 3,71%, prosječno izgubljeno vrijeme po vozilu je smanjeno za 7,60%, ukupno vrijeme zaustavljanja je smanjeno za 9,37% dok je ukupni broj stajanja svih vozila smanjen za 2,74%.


Tablica 6: Ukupni rezultati trećeg scenarija

Parametar	Ustaljeni signalni plan	SOM 484 neurona i Q učenje					
		1. iteracija učenja		50. iteracija učenja		100. iteracija učenja	
		Iznos	Promjena [%]	Iznos	Promjena [%]	Iznos	Promjena [%]
$TT_{TOT}$ [s]	2287484	2325185	1,65%	2232969	-2,38%	2202657	-3,71%
$LT_{AVG}$ [s/voz]	23,11	23,58	2,05%	21,80	-5,64%	21,35	-7,60%
$ST_{TOT}$ [s]	805762	839691	4,21%	756988	-6,05%	730249	-9,37%
$NS_{TOT}$	30112	30811	2,32%	29702	-1,36%	29288	-2,74%


#### 6.3.4. Ukupni rezultati po iteracijama učenja

Ukupni rezultati svih scenarija u ovisnosti o iteraciji učenja prikazani su grafikonima 9, 10, 11 i 12. U svim grafikonima ukupnih rezultata vidljivo je ponašanje konvergencije rezultata. Prvi i drugi scenarij započinju konvergenciju oko 40. iteracije učenja, dok se za treći scenarij ne može

utvrditi konvergencija rezultata čak ni nakon 100 iteracija učenja. Ovi rezultati pokazuju kako se povećanjem broja neurona SOM mreže brzina učenja smanjuje zbog velikog broj stanja za koja je potrebno naučiti zakon upravljanja.




Grafikon 9: Ukupno vrijeme putovanja svih vozila




Grafikon 10: Prosječno izgubljeno vrijeme po vozilu





Grafikon 11: Ukupno vrijeme zaustavljanja svih vozila



Grafikon 12: Ukupni broj zaustavljanja svih vozila

Analizom prometnih parametara utvrđuje se pozitivan učinak sustava za upravljanje izoliranim semaforiziranim raskrižjem primjenom SOM mreže i Q-učenja. Smanjenjem vremena putovanja postiže se učinkovitiji rad prometnog sustava, kao i smanjenje troškova. Smanjenjem broja i trajanja zaustavljanja smanjuje se potrošnja energenata, smanjuju emisije štetnih plinova i podiže razina usluge raskrižja.

## 7. Zaključak

Primjenom neuronske mreže i strojnog učenja prilikom upravljanja semaforiziranim raskrižjem moguće je postići poboljšanja u radu prometnog sustava. Pri tome je poboljšanja moguće postići tijekom rada upravljačkog sustava kako upravljački sustav ima mogućnost učenja na osnovi ocjene primijenjene upravljačke akcije. U ovom diplomskom radu je simulirano izolirano semaforizirano raskrižje uz primjenu Kohonenove SOM neuronske mreže za određivanje stanja raskrižja kao ulaznim parametrom algoritma Q-učenja. Broj analiziranih stanja ovisio je veličini SOM neuronske mreže dok se skup akcija sastojao od sedam definiranih signalnih planova. Iz rezultata je vidljivo da sustav učenja brže dolazi do optimalnog zakona upravljanja raskrižjem uz manji broj analiziranih stanja. Rezultati pokazuju da korištenjem velikog broja neurona dolazi do smanjenja kvalitete upravljanja, što se može pripisati otežanom učenju zbog velikog broja proučavanih prometnih stanja.

Spajanjem mikroskopskog simulatora VISSIM i biblioteke AForge stvoreno je simulacijsko okruženje za razvoj i analizu ITS sustava zasnovanih na primjeni umjetne inteligencije. Kroz iterativno učenje postignuto je smanjenje ukupnog trajanja putovanja za 5,65%, smanjenje prosječnog izgubljenog vremena za 11,54%, smanjenje trajanja zaustavljanja za 14,09% i smanjenje broja zaustavljanja za 4,96% u usporedbi s ustaljenim signalnim planom.

Nedostatak primjene ovakvog sustava je u teškom određivanju broja neurona SOM mreže zbog izravne povezanosti s brzinom prilaska stacionarnom stanju te dobrog opisa svih potencijalnih stanja upravljane prometne mreže. Nastavak istraživanja se vidi u analizi brzine reakcije sustava na iznenadne promjene u ponašanju korisnika prometnog sustava, ili pojavu incidentne situacije. Također je potrebno obratiti pozornost prema mogućnostima primjene SOM neuronske mreže i Q-učenja na nizu više ulančanih semaforiziranih raskrižja te u integraciji dodatnih ITS sustava poput dodjele prioriteta vozilima javnog gradskog prijevoza ili žurnih službi.

## Popis literature

- [1] Costa P.B., Morais Neto G.C., Bertolde A.I. Urban mobility indexes: A brief review of the literature. *Transportation Research Procedia*, 25:3645–3655, 2017.
- [2] Miletić, M. Simulacija semaforizirane urbane prometne mreže korištenjem PTV VISSIM-a te MATLAB-a. Završni rad, Fakultet prometnih znanosti, Sveučilište u Zagrebu, 2017.
- [3] Anžek, M. „Cestovna telematika - Povijest Cestovne Telematike“, predavanja, Fakultet prometnih znanosti, Zagreb, 2016.
- [4] Kapusta, B., Miletić, M., Ivanjko, E., Vujić, M. Preemptive traffic light control based on vehicle tracking and queue lengths. In *Proceedings of 59th International Symposium ELMAR-2017*, pages 11–16, Zadar, Croatia, September 2017.
- [5] Miletić, M., Kapusta, B., Ivanjko, E. Comparison of two approaches for preemptive traffic light control. In *Proceedings of 60th International Symposium ELMAR-2018*, pages 57–62, Zadar, Croatia, September 2018.
- [6] Vogel, A., Oremović, I., Šimić, R., Ivanjko, E. Improving traffic light control by means of fuzzy logic. In *Proceedings of 60th International Symposium ELMAR-2018*, pages 51–56, Zadar, Croatia, September 2018.
- [7] Vujić, M. Sustav dinamičkih prioriteta za vozila javnog gradskog prijevoza u automatskom upravljanju prometom. Doktorska disertacija, Fakultet prometnih znanosti, Sveučilište u Zagrebu, 2013.
- [8] Kapusta, B., Miletić, M. Analiza utjecaja adaptivnog upravljanja signalnim planovima semaforiziranog raskrižja na vrijeme putovanja vozila žurnih službi. Rektorova nagrada, Sveučilište u Zagrebu, Zagreb, 2017.
- [9] Bošnjak, I. *Inteligentni transportni sustavi 1*. Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2006.

- [10] ISO norma 4813-1:2015. <https://www.iso.org/standard/57393.html> pristupljeno: svibanj 2019.
- [11] PTV VISSIM. <http://vision-traffic.ptvgroup.com/en-us/products/ptv-vissim/> pristupljeno: lipanj 2019.
- [12] AForge.NET framework. <http://www.aforgenet.com/framework/> pristupljeno: lipanj 2019.
- [13] Bošnjak, I., Badanjak, D. *Osnove prometnog inženjerstva*. Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2005.
- [14] Zakon o sigurnost prometa na cestama. Narodne Novine, br. 67., 16.11.2017., čl. 59.
- [15] Anžek, M., Divić, A., Lanović, Z. Smjernice za prometnu svjetlosnu signalizaciju na cestama. Ministarstvo pomorstva, prometa i veza, Zagreb, 2001.
- [16] Lanović, Z. Cestovna telematika - Signalni plan - vježbe. Fakultet prometnih znanosti, Zagreb, 2016.
- [17] Peter Koonce, Lee Rodegerdts, Kevin Lee, Shaun Quayle, Scott Beaird, Cade Braud, Jim Bonneson, Phil Tarnoff, Tom Urbanik. Traffic Signal Timing Manual. Federal Highway Administration, Turner-Fairbank Highway Research Center, 6300 Georgetown Pike, 2006.
- [18] Traffic design manual. Traffic Operations Division, Traffic Engineering Office, 2016.
- [19] Ekeila, W. Dynamic transit signal priority. Master Thesis, University of Sharjah, 2002.
- [20] Gold, H., Ivanjko, E. Umjetna inteligencija - predavanja. Fakultet prometnih znanosti, Zagreb, 2018.
- [21] George F. Luger. *Artificial Intelligence - Structures and Strategies for Complex Problem Solving, sixth edition*. Pearson - Addison Wesley, 2009.
- [22] Artificial neural networks technology. <http://www.psych.utoronto.ca/users/reingold/courses/ai/cache/neural3.html> pristupljeno: lipanj 2019.
- [23] Kohonen, T. Essentials of the self-organizing map. *Neural Netw.*, 37:52–65, January 2013.
- [24] Primc. M. Linearna algebra. <https://web.math.pmf.unizg.hr/nastava/laf/data/knjiga11-2.pdf> pristupljeno: lipanj 2019.

- [25] Self-organising maps. <http://www.uta.fi/sis/tie/neuro/index/Neurocomputing3.pdf> pristupljeno: lipanj 2019.
- [26] Kohonen's self organizing feature maps. <http://www.ai-junkie.com/ann/som/som5.html> pristupljeno: lipanj 2019.
- [27] Kušić K. Okruženje za simulaciju sustava za upravljanje promjenjivim ograničenjem brzine na urbanim autocestama zasnovanih na učenju [diplomski rad]. Zagreb: Sveučilište u Zagrebu, Fakultet prometnih znanosti; 2017 [pristupljeno 22.06.2019.] Dostupno na: <https://urn.nsk.hr/urn:nbn:hr:119:016117>.
- [28] Kumar. V. Reinforcement learning: Temporal-Difference, SARSA, Q-Learning & Expected SARSA in Python. <https://towardsdatascience.com/reinforcement-learning-temporal-difference-sarsa-q-learning-expected-sarsa-on-python-9fecfda7467e> pristupljeno: lipanj 2019.
- [29] Walraven, E. Traffic flow optimization using reinforcement learning - master's thesis. Faculty EEMCS, Delft University of Technology, Delft, the Netherlands, 2014.
- [30] Kušić, K., Ivanjko, E., Gregurić, M. A comparison of different state representations for reinforcement learning based variable speed limit control. Proceedings of the 26th Mediterranean Conference on Control and Automation MED2018, 19-22 June, Zadar, Croatia, 2018, pp. 266-271. DOI: 10.1109/MED.2018.8442986.
- [31] Ying-Cih Kao and Cheng-Wen Wu. A Self-Organizing Map-Based Adaptive Traffic Light Control System with Reinforcement Learning, Oct 2018. DOI: 10.1109/ACSSC.2018.8645125.
- [32] T. Nakatsuji, S. Seki, S. Shibuya, and T. Kaku. Artificial intelligence approach for optimizing traffic signal timings on urban road network. In *Proceedings of VNIS'94 - 1994 Vehicle Navigation and Information Systems Conference*, pages 199–202, Aug 1994. DOI: 10.1109/VNIS.1994.396841.
- [33] Chang-Hsian Uang, Jiun-Wei Liou, and Cheng-Yuan Liou. Self-organizing reinforcement learning model. In *Intelligent Information and Database Systems, Asian Conference on Intelligent Information and Database Systems (ACIIDS2012), Lecture Notes in Computer Science*, 2012. DOI: 10.1007/978-3-642-28487-8-22.

[34] NET TO VISSIM. [https://github.com/MladenMiletic/NET\\_TO\\_VISSIM](https://github.com/MladenMiletic/NET_TO_VISSIM) pristupljeno: lipanj 2019.

[35] Projekt SORDITO. <https://www.fpz.unizg.hr/sordito/> pristupljeno: lipanj 2019.

## Popis ilustracija

1	Poopćeni model prometnog sustava [13] . . . . .	5
2	Komponente izračuna zaštitnog međuvremena [7] . . . . .	9
3	Primjer vremenski ustaljenog signalnog plana [16] . . . . .	10
4	Prikaz prstenastog NEMA signalnog plana [18] . . . . .	11
5	Prikaz modela i okoline ekspertnog sustava [20] . . . . .	15
6	Prikaz biološkog neurona [20] . . . . .	16
7	Model umjetnog neurona [20] . . . . .	16
8	Model umjetne neuronske mreže s ulaznim, skrivenim i izlaznim slojem . . . .	17
9	SOM model s 25 neurona skrivenog sloja i $n_I$ neurona ulaznog sloja . . . . .	20
10	Sustav za upravljanje raskrižjem korištenjem Q-učenja zasnovan na neuronskoj mreži . . . . .	29
11	Prikaz rada modula animacije simulatora VISSIM . . . . .	31
12	Simulacijsko okruženje NET TO VISSIM . . . . .	32
13	VISSIM model izoliranog raskrižja: Ulica kralja Zvonimira - Ulica Vjekoslava Heinzela . . . . .	33
14	Ustaljeni signalni plan: Ulica kralja Zvonimira - Ulica Vjekoslava Heinzela [7]	36
15	SOM mreža s 18 neurona ulaznog sloja i 16 neurona skrivenog sloja . . . . .	38
16	SOM mreža s 18 neurona ulaznog sloja i 25 neurona skrivenog sloja . . . . .	39
17	SOM mreža s 18 neurona ulaznog sloja i 484 neurona skrivenog sloja . . . . .	40
18	Signalni planovi odnosno akcije za upravljanje . . . . .	41

## Popis tablica

1	Parametri učenja SOM mreže . . . . .	38
2	Parametri Q-učenja . . . . .	42
3	Simulacijske postavke prema scenarijima . . . . .	43
4	Ukupni rezultati prvog scenarija . . . . .	44
5	Ukupni rezultati drugog scenarija . . . . .	45
6	Ukupni rezultati trećeg scenarija . . . . .	46



## Popis grafikona

1	Generirana prometna potražnja: Ulica Vjekoslava Heinzela sjever . . . . .	34
2	Generirana prometna potražnja: Ulica Vjekoslava Heinzela jug . . . . .	34
3	Generirana prometna potražnja: Ulica kralja Zvonimira - istok . . . . .	35
4	Generirana prometna potražnja: Ulica kralja Zvonimira - zapad . . . . .	35
5	Promjena parametra $\epsilon$ u ovisnosti o rednom broju simulacije . . . . .	42
6	Ukupno vrijeme putovanja svih vozila - Scenarij 1 . . . . .	44
7	Ukupno vrijeme putovanja svih vozila - Scenarij 2 . . . . .	45
8	Ukupno vrijeme putovanja svih vozila - Scenarij 3 . . . . .	46
9	Ukupno vrijeme putovanja svih vozila . . . . .	47
10	Prosječno izgubljeno vrijeme po vozilu . . . . .	47
11	Ukupno vrijeme zaustavljanja svih vozila . . . . .	48
12	Ukupni broj zaustavljanja svih vozila . . . . .	48



Sveučilište u Zagrebu  
Fakultet prometnih znanosti  
10000 Zagreb  
Vukelićeva 4

## IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj \_\_\_\_\_ diplomski rad  
isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na  
objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

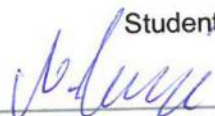
Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz  
necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj  
visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu \_\_\_\_\_ diplomskog rada  
pod naslovom **ADAPTIVNO UPRAVLJANJE IZOLIRANIM SEMAFORIZIRANIM  
RASKRIŽJEM PRIMJENOM NEURONSKIH MREŽA**

na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom  
repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

U Zagrebu, 05/07/2019 \_\_\_\_\_

Student/ica:  
  
\_\_\_\_\_  
(potpis)