

MEĐIMURSKO VELEUČILIŠTE U ČAKOVCU  
STRUČNI STUDIJ RAČUNARSTVA

ANJA FARKAŠ

**MODEL *NEURO-FUZZY* SUSTAVA ZA PROCJENU  
RIZIKA OD PREKIDA STUDIRANJA NA MEV-u**

ZAVRŠNI RAD

ČAKOVEC, 2016.

MEĐIMURSKO VELEUČILIŠTE U ČAKOVCU  
STRUČNI STUDIJ RAČUNARSTVA

ANJA FARKAŠ

**MODEL *NEURO-FUZZY* SUSTAVA ZA PROCJENU  
RIZIKA OD PREKIDA STUDIRANJA NA MEV-u**

Model of *neuro-fuzzy* system for study interruption risk assesment  
on Polytechnic of Međimurje in Čakovec

ZAVRŠNI RAD

Mentor : mr. sc. Željko Knok

ČAKOVEC, 2016.

## *ZAHVALA*

*Veliku zahvalnost, u prvom redu, dugujem svome mentoru mr.sc. Željku Knoku, v. pred. koji je svojim znanstvenim i stručnim savjetima oblikovao ideju i pomogao mi u izradi ovoga završnog rada.*

*Posebnu zahvalnost iskazujem cijeloj svojoj obitelji koja me uvijek podržavala i upućivala na pravi put.*

*Također zahvaljujem svim svojim kolegicama i kolegama koji su uvijek bili uz mene te učinili studiranje lakšim i zabavnijim.*

## SADRŽAJ

|  |           |
|--|-----------|
| Sažetak.....   | 1         |
| Abstract.....  | 2         |
| <b>UVOD.....</b>   | <b>3</b>  |
| <b>1.FUZZY LOGIKA.....</b>   | <b>4</b>  |
| 1.1. Fuzzy(neizraziti) skupovi.....  | 5         |
| 1.2. Funkcije pripadnosti.....   | 7         |
| 1.3. Karakteristični oblici funkcije pripadnosti.....                                  | 7         |
| 1.4. Fuzzy sustav za zaključivanje.....  | 8         |
| <b>2.NEURONSKE MREŽE.....</b>  | <b>10</b> |
| 2.1. Podjela neuronskih mreža.....   | 10        |
| 2.1.1. Biološke neuronske mreže.....   | 11        |
| 2.1.2. Umjetne neuronske mreže.....  | 12        |
| 2.2. Prednosti i nedostaci neuronskih mreža.....                                       | 13        |
| 2.2.1. Prednosti neuronskih mreža.....   | 14        |
| 2.2.2. Nedostaci neuronskih mreža.....   | 14        |
| 2.3. Učenje neuronske mreže.....   | 14        |
| 2.3.1. Nadgledano učenje.....  | 14        |
| 2.3.1.1. <i>Back-propagation</i> algoritam.....  | 15        |
| 2.3.2. Nenadgledano učenje.....  | 15        |
| 2.4. Na koji način se učenjem stvara neuronska mreža?.....                             | 16        |
| 2.4.1. Faza učenja.....  | 16        |
| 2.4.2. Testiranje mreže.....   | 17        |
| 2.5. ANFIS ( <i>engl. adaptive neuro-fuzzy inference system</i> ) neuronska mreža..... | 18        |

|  |           |
|--|-----------|
| <b>3. MODELIRANJE INTELIGENTNOG SUSTAVA.....</b> | <b>20</b> |
| 3.1. Predprocesiranje.....                       | 20        |
| 3.2. Modeliranje ANFIS-a.....                    | 23        |
| 3.2.1. Modeliranje ANFIS-a 1.....                | 26        |
| 3.2.2. Modeliranje ANFIS-a 2.....                | 32        |
| <b>4. SIMULACIJA.....</b>                        | <b>37</b> |
| <b>5. ZAKLJUČAK.....</b>                         | <b>38</b> |
| <b>6. LITERATURA.....</b>                        | <b>39</b> |

## SAŽETAK

*Primjena novih tehnologija i tehnika kao što su neuronske mreže, ekspertni sustavi, fuzzy logika, prepoznavanje uzoraka i sl., pruža nam nove mogućnosti u obradi podataka. U radu će se najviše govoriti o primjeni i mogućnostima koje nam pružaju fuzzy logika i neuronske mreže. Pod pojmom neuronske mreže podrazumijevat će se umjetne neuronske mreže (ANN-artificial neural network). Naime, neuronske mreže relativno su novi koncept koji se koristi u analizi podataka. Njihova primjena može se koristiti u tehničkim i društvenim znanostima, ekonomiji te mnogim drugim područjima. Izrazito visoku primjenu neuronske mreže imaju u području klasificiranja i predviđanja. Istraživanja su pokazala da neuronske mreže funkcioniraju na sličan način kao ljudski mozak. Neuronski sustav razvija se pomoću treninga na velikom broju primjera te se dobiveno rješenje utvrđuje na pravilima već definiranog znanja. Neuronske mreže karakterizira visok stupanj tolerancije grešaka. Čak i u slučaju nejasnih podataka, moguće je doći do zadovoljavajućeg rješenja.*

*U ovom radu prikazan je dio rezultata koji se odnosi na mogućnosti primjene umjetnih neuronskih mreža (ANN) u obradi podataka, a posebno u području klasificiranja i predviđanja.*

*Modeliranjem i izgradnjom sustava klasificirat će se oni studenti kod kojih postoji rizik od prekida studiranja na MEV-u. Pomoću inteligentnog sustava izgradit će se hibridni model koji čini sinteza fuzzy logike i neuronske mreže, a u MATLAB okruženju predstaviti će se ANFIS (adaptive neuro-fuzzy inference system).*

*Ključne riječi: ANFIS (adaptive neuro-fuzzy inference system), ANN (artificial neural networks), fuzzy logika.*

## **ABSTRACT**

*Application of new technologies and techniques as neural networks, expert systems, fuzzy logic, sample recognition and etc. gives us new possibilities in data processing. In current thesis the most applicable topic will be applications and possibilities of fuzzy logic and neural networks. The term "neural network" means artificial neural networks (ANN - artificial neural network) and it's a relatively new concept used in data processing analysis. Neural networks could be applicable in full range of different fields like engineering, social science, economy and many others. Extremely high application of neural networks is in the area of classification and prediction. According to researches, neural networks work in the same way as the human brain. A neural system is developed by training based on a large number of examples, while the final result is established on rules of already defined knowledge. Neural networks are characterized by a high degree of fault tolerance; even in the case of unclear data it's possible to reach a satisfactory solution.*

*Current thesis presents results which relate to application possibilities of artificial neural networks (ANN) in data processing, especially in field of classification and prediction.*

*Modeling and construction of the system will classify those students who are at risk of interruption of studies on Polytechnic of Međimurje in Čakovec. Through intelligent system a hybrid model will be built, which constitutes the synthesis of fuzzy logic and neural networks, while in the MATLAB environment ANFIS (adaptive neuro-fuzzy inference system) will be presented.*

*Key words: ANFIS (adaptive neuro-fuzzy inference system), ANN (artificial neural networks), fuzzy logic.*

## **UVOD**

Nakon upisa na fakultet, teško je procijeniti rizik od prekida studiranja. Upravo zbog tog problema, cilj ovog završnog rada je izrada inteligentnog sustava na bazi umjetne neuronske mreže. Modeliranjem i izgradnjom sustava klasificirat će se oni studenti kod kojih postoji rizik od prekida studiranja na Međimurskom veleučilištu u Čakovcu.

Podaci koji će se koristiti u svrhu rješavanja problema u završnom radu prikupljeni su na temelju državne mature i upisa na Međimursko veleučilište u Čakovcu. Podaci sadrže 192 uzoraka s 10 atributa.

Od ukupno 10 atributa izdvojena su njih 5 koji su od izuzetne važnosti za model, a to su: plasman, izbor, bodovi iz škole, bodovi s državne mature i ukupan broj bodova.

Prikupljeni podaci se filtriraju i normaliziraju, te nakon toga raspodjeljuju na skupove za učenje, tj. treniranje i testiranje.

Početni ANFIS sustav dijeli se na dva podsustava (ANFIS1 i ANFIS2) zbog velikog broja atributa. Treniranjem i testiranjem dobivenih FIS (*engl. fuzzy inference system*) stuktura odabire se ona mreža s najmanjom greškom. Simulacijom pomoću *simulinka* prezentiran je rad mreže.




## 1. FUZZY LOGIKA

Engleska riječ *fuzzy* [fazi] znači nešto nejasno, mutno, neizrazito.

Izraz neizrazita (*fuzzy*) logika danas se koristi za bilo koje od dva različita značenja, kako prikazuje slika 1. Sam Lotfi A. Zadeh ovo je 1994. godine opisao sljedećim riječima:

„Izraz neizrazita logika upotrebljava se u dva različita smisla. Uži smisao je logički sustav koji je proširenje viševrijednosne logike i služi kao logika približnog zaključivanja. U širem smislu to je sinonim za teoriju neizrazitih skupova, teoriju razreda s nejasnim granicama. Danas se izraz neizrazita logika pretežno upotrebljava u ovom širem smislu.“

Slika 1. Značenje pojma neizrazita (*fuzzy*) logika



Izvor: Marko Čupić, Bojana D. Bašić, Marin Golub (2013.) Neizrazito, evolucijsko i neuroračunarstvo, knjiga

### **1.1. Fuzzy (neizraziti) skupovi**

*Fuzzy* skupovi su osnovni elementi za obradu nejasnoće i neodređenosti u *fuzzy* logici. *Fuzzy* skupovi predstavljaju skup elemenata sa sličnim svojstvima (npr. skup visokih ljudi, skup niskih ljudi, skup brzih automobila itd.), a klasičan skup sadrži elemente s istim svojstvima pri čemu svaki element pripada 100 % tom skupu (npr. skup jabuka, skup krušaka, skup cijelih brojeva itd.)

U klasičnim skupovima element ili pripada ili ne pripada određenom skupu. Matematički se to može predstaviti ovako: stupanj pripadnosti je 1 ako pripada ili 0 ako ne pripada skupu. Elementi u *fuzzy* skupovima mogu djelomično pripadati. Matematički se to može predstaviti na sljedeći način: 1 (100% pripada), 0 (uopće ne pripada skupu), 0.7 (70% pripada skupu). Ovim pristupom može se preciznije prikazati neprecizne skupove.

#### Primjer 1:

Ako je za primjer zadan univerzalni skup „dani u 2001. godini“ s ciljem određivanja skupa „dani koji su bili sunčani“, kako će se odrediti koji dani pripadaju u skup sunčanih dana?

Može se pokušati ovako: u skup sunčanih dana pripadaju svi oni dani kada na nebu nije bilo niti jednog oblaka.

No što je s danima u kojima je na pet minuta u nekom kutku neba naišao neki oblačak? Pripadaju li oni u skup sunčanih dana? A što je s danima u kojima se na deset minuta pojavio neki oblačak? Na petnaest minuta? Na dvadeset minuta?

Primjer 2:

Zadan je univerzalni skup koji čine svi ljudi koji žive u gradu Zagrebu. Treba odrediti koji od tih ljudi pripadaju u skup visokih ljudi. Kako se ovo može napraviti? Kada bi se radilo s klasičnim skupovima, morala bi se odrediti neka granična visina i sve ljude koji su visoki barem toliko, uvrstiti u skup. Za primjer se može odrediti da je granična visina 180 cm. Tada će u skup visokih ljudi ući svi oni koji su visoki 180 cm ili više.

Međutim, je li ovo dobar način za stvaranje skupa visokih ljudi? Može se pogledati jedna trivijalna posljedica ovakvog stvaranja skupa: Pero Perić koji je visok 180 cm pripada skupu visoki ljudi, ali Ivica Ivić koji je visok 179.98 cm ne pripada. Granica se može pomaknuti na 179.98 cm tako da i Ivica Ivić bude član visokih ljudi. Ali, eto novog problema – Ante Antić koji je visok 179.97 cm ne pripada tom skupu iako nitko golim okom ne može uočiti da je on niži od Ivica Ivića koji jest u skupu. Mora li se opet pomicati granica?


Iz ovih dvaju primjera jasno se vidi da se prilikom određivanja klasičnih skupova javlja jedan vrlo neugodan problem – kako odrediti što pripada takvom skupu, a da granica bude jasna i, što je još važnije, da ima veze sa zdravim razumom? Naime, kaže li se da je granica 180 cm, bit će potpuno jasno, no vidi se da to nikako nije dobar način jer jednostavno nije smislen. Ovakve poteškoće jedan su od razloga nastanka teorije neizrazitih skupova.

## 1.2. Funkcije pripadnosti

Funkcija pripadnosti (*engl. membership function*) određuje stupanj pripadnosti nekog elementa.

Funkcije pripadnosti imaju svojstva koja su specifična za sve vrste funkcija pripadnosti, a to su: osnovica, jezgra, visina, granica i polovište.

Slika 2. Svojstva funkcije pripadnosti



Izvor: prezentacija Membership function and fuzzification [ 1 ]

## 1.3. Karakteristični oblici funkcija pripadnosti

Za modeliranje se mogu koristiti različiti oblici neizrazitih skupova, a to su: trapez, trokut, generalizirano zvono, Gaussianova krivulja i dr.

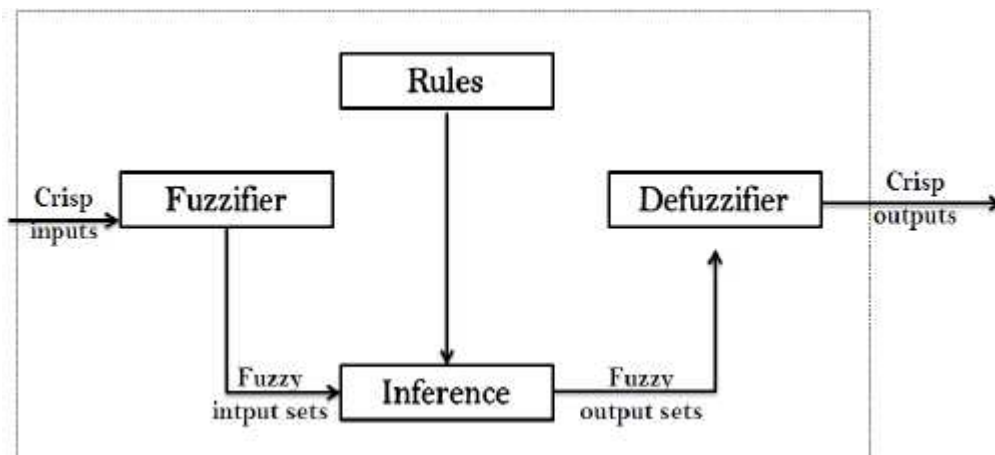
Oblik trokuta najčešće se koristi kod fazifikacije, a kod agregacije se koristi trapez. Svaka funkcija ovisi o slučaju.

#### 1.4. Fuzzy sustav za zaključivanje

Fuzzy sustav za zaključivanje (engl. *fuzzy inference system*) sastoji se od tri koncepta znanja, a to su: teorija *fuzzy* skupova, *fuzzyif-then* pravila i *fuzzy* zaključivanje.

Fuzzy sustav za zaključivanje sadrži tri osnovne komponente : bazu pravila, rječnik i mehanizme za zaključivanje. Baza pravilasastoji se od *if-then* pravila. U rječniku su definirane funkcije pripadnosti koje se koriste uz *fuzzy* pravila. Mehanizam za zaključivanje pomoću parametara daje zaključak. Najčešće korištene *fuzzy* tehnike zaključivanja su *Mamdani* i *Sugeno*.

Slika 3. Blok dijagram fuzzy sustava



Izvor: [https://www.researchgate.net/figure/283621634\\_fig1\\_Figure-2-Block-diagram-of-a-fuzzy-logic-system-32](https://www.researchgate.net/figure/283621634_fig1_Figure-2-Block-diagram-of-a-fuzzy-logic-system-32)

Fuzzy sustav ne može raditi bez dvaju glavnih procesa, a to su fazifikacija i defazifikacija, te baze pravila i agregacije.

Baza pravila – sadrži znanje o tome kako je najbolje kontrolirati sistem i to u formi skupa logičkih (*if-then*) pravila.

*If-then* pravila su pravila po kojima *fuzzy* logika donosi neki zaključak.

Izgled *if-then* pravila:

IF x je A THEN Y je B

U ovakvom pravilu „x je A,, predstavlja premisu (predstavlja propoziciju ili pretpostavku, nešto što je naprijed istaknuto), a „y je B “ zaključak .

Fazifikacija – *fuzzy* pretvorba ili fazifikacija transformira *crisp* ulazne parametre (*crisp* ulazni parametri zapravo su numeričke vrijednosti koje se pretvaraju u odgovarajuće jezične vrijednosti) u *fuzzy* ulazne parametre.

Agregacija – proces agregacije zapravo je proces kombiniranja *fuzzy* rezultata pomoću pravila u kojem se dobije konačan *fuzzy* rezultat koji se šalje u proces defazifikacije, tj. kodiranje. Agregacija se svodi na logičke operacije (konjunkcija ili disjunkcija, odnosno T ili S-norma).

Defazifikacija – drugi i završni korak u *fuzzy* logici je defazifikacija. Defazifikacija je proces suprotan fazifikaciji.

## **2. NEURONSKE MREŽE**

Što su to neuronske mreže?

Neuronske mreže su računalni modeli sastavljeni od više jednostavnih elemenata za obradu podataka. Funkcioniraju na sličan način kao ljudski mozak. Sastavljene su od neurona. Svaki od njih ima lokalnu memoriju u kojoj pamti podatke koje obrađuje. Ključni element ovog modela je struktura sustava za obradu podataka. Ona se sastoji od velikog broja međusobno povezanih elemenata (neurona) koji skladno rade u svrhu što boljeg rješavanja konkretnog problema. Neuronske mreže odlično rješavaju probleme klasifikacije i predviđanja, odnosno općenito sve probleme kod kojih postoji odnos ulaznih i izlaznih varijabli, bez obzira na visoku složenost te veze. Svaka mreža je konfigurirana za određenu primjenu, kao što je obrada slike, govora, prepoznavanje uzoraka itd.

### **2.1. Podjela neuronskih mreža**

Od samog početka svoje prisutnosti u znanosti, ispitivane su s dva različita pristupa – biološkog i tehnološkog. Iako su umjetne neuronske mreže nastale po uzoru na biološke neuronske mreže, ova dva modela međusobno se razlikuju.


Biološki pristup istražuje neuronske mreže kao pojednostavljene simulacije ljudskog mozga, a drugi pristup tretira neuronske mreže kao tehnološke sustave za složenu obradu informacija.

### **2.1.1. Biološke neuronske mreže**

Biološke neuronske mreže sastavni su dio čovjeka čiji se mozak sastoji od 100 milijardi neurona, a zaslužne su za izvođenje vrlo važnih funkcija kao što su razmišljanje, učenje, emocije, percepcija, motorika itd. Iako se funkcije neuronskih mreža istražuju već dugi niz godina, brojni procesi, kao i njihov način rada, ljudskom umu još uvijek nisu u potpunosti razumljivi.

Biološki neuron – stanica koja prima informacije od drugih neurona putem dendrita, obrađuje ih, a zatim šalje impuls putem aksona i sinapsi drugim neuronima u mreži. Učenje se odvija promjenom jačine sinaptičkih veza. Milijuni neurona u mreži mogu paralelno obrađivati informacije.

Slika 4. *Shematski prikaz biološkog neurona*



Izvor: <http://zdravlje.eu/2011/04/11/neuron/neuron-2/>



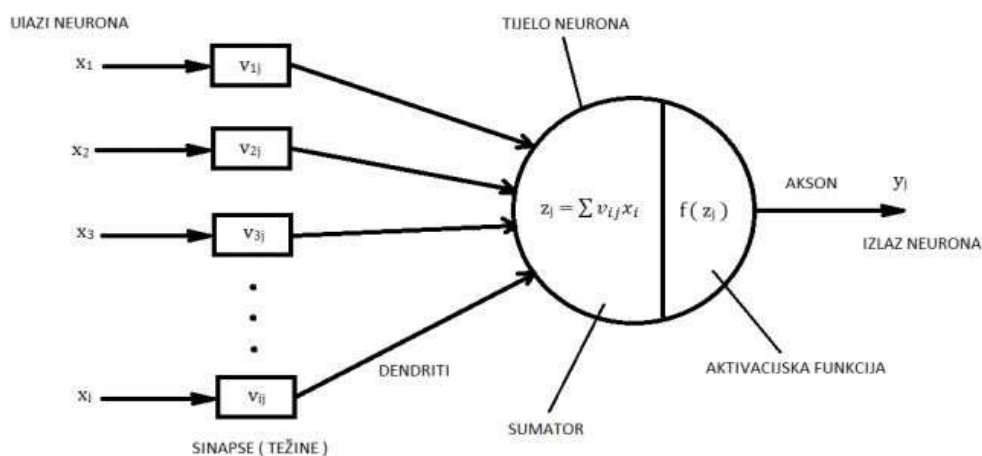
### 2.1.2. Umjetne neuronske mreže (engl. ANN-artificial neural networks)

Umjetna neuronska mreža građena je od međusobno povezanih umjetnih neurona. Koriste se za razumijevanje bioloških neuronskih mreža ili za rješavanje problema na području umjetne inteligencije.

Umjetne neuronske mreže funkcioniraju na sličan način kao i biološke mreže – pokušavaju imitirati funkcioniranje mozga. Sumator umjetnog neurona zamjenjuje tijelo biološkog neurona, dok ulogu dendrita preuzimaju ulazi u sumator, a izlaz iz sumatora je akson umjetnog neurona. Prag osjetljivosti umjetnog neurona je izveden pomoću aktivacijske funkcije te ona simulira prag osjetljivosti biološkog neurona. Ostvarivanje veze umjetnog neurona s njegovom okolinom postiže se pomoću težinskih faktora koji preslikavaju funkcije sinaptičke veze biološkog neurona. Zbog kombinacije velikog broja međusobno povezanih elemenata (neurona ili čvota) moguće je pohraniti te obrađivati i vrlo složene informacije.

Umjetna neuronska mreža ima široku primjenu u društvenim i tehničkim znanostima. Koristi se za rješavanje zadataka kao što su prepoznavanje uzoraka, obrada slike, govora, simulacije i obrade nepreciznih podataka. Pozitivne značajke umjetne neuronske mreže su: uče iz iskustva, mogu raditi s velikim brojem varijabli i mogu se prilagoditi okolini.

Slika 5. Shematski prikaz umjetnog neurona

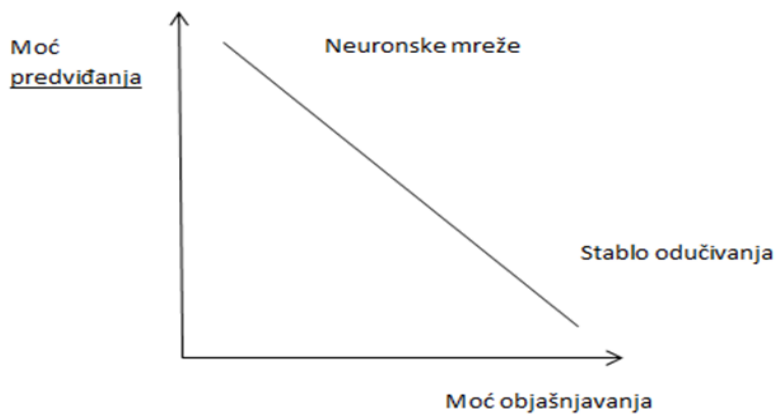


Izvor: [http://www.phy.pmf.unizg.hr/~planinic/diplomski/Kenan\\_Mackic.pdf](http://www.phy.pmf.unizg.hr/~planinic/diplomski/Kenan_Mackic.pdf)

## 2.2. Prednosti i nedostaci neuronskih mreža

Na dijagramu (slika 6.) je prikazana moć predviđanja i moć objašnjavanja. Vidi se da neuronske mreže odlično predviđaju, a slabo objašnjavaju, potpuno suprotno od stabla odlučivanja. Naime, neuronska mreža ne može objasniti kako je došla do određenog rezultata, tj. rješenja, jer je u neuronskoj mreži znanje o obradi podataka pohranjeno u obliku različitih težinskih koeficijenata koje je teško predstaviti čovjeku u obliku pravila. Zato se neuronske mreže koriste samo kada je bitan rezultat klasifikacije, a nije bitno pravilo po kojem se došlo do rezultata.

Slika 6. Dijagram zavisnosti moći predviđanja i objašnjavanja



Izvor: ([http://nastava.fpmoz.ba/nastava/diplomski/fpmoz\\_diplomski\\_informatika\\_matic.pdf](http://nastava.fpmoz.ba/nastava/diplomski/fpmoz_diplomski_informatika_matic.pdf))

### **2.2.1. Prednosti neuronskih mreža:**

- uče na osnovi primjera
- imaju moć predviđanja i klasificiranja
- prepoznavanje oblika
- rješavaju gotovo sve probleme bolje nego statističke i tradicionalne metode
- sposobnost generalizacije

### **2.2.2. Nedostaci neuronskih mreža:**

- uspješno učenje zahtijeva velik broj podataka
- imaju slabu moć objašnjavanja
- nisu pogodne za aritmetičke proračune i zadatke obrade podataka
- ne mogu davati odgovore izvan raspona u kojem uče
- teškoće u korištenju (vrijeme treniranja)

### **2.3. Učenje neuronske mreže**

Najvažnije svojstvo neuronske mreže je sposobnost učenja, tj. stjecanja iskustava, a iskustvo se dobiva iz podataka koje obrađuje. Neuronsku se mrežu može učiti na dva načina: nadgledano (*engl. supervised*) i nenadgledano (*engl. unsupervised*) učenje.

### 2.3.1. Nadgledano učenje

Nadgledano učenje je tip učenja kod kojeg sustav sam podešava parametre na temelju podataka s poznatim ulaznim i izlaznim vrijednostima. Najčešće korišteni algoritmi za nadgledano učenje su *back-propagation* i *perceptron* algoritam. Ovdje će se definirati i opisati samo *back-propagation* algoritam jer će se on koristiti u radu.

#### 2.3.1.1. *Back-propagation* algoritam

Algoritam mreže "širenje unatrag" neuronske mreže učinio je široko upotrebljivom i popularnom metodom u različitim područjima. Bila je to prva neuronska mreža s jednim ili više skrivenih slojeva. U osnovi, ova mreža propagira *input* kroz mrežu od ulaznog do izlaznog sloja, a zatim određuje grešku i tu grešku propagira unazad sve do ulaznog sloja ugrađujući je u formulu za učenje. Standardni algoritam mreže "širenje unatrag" uključuje optimizaciju greške koristeći deterministički algoritam gradijentnog opadanja (*engl. gradient descent*).

### 2.3.2. Nenadgledano učenje

Nenadgledano učenje suprotno je nadgledanom jer sustav sam otkriva odnose između podataka prema opisanim značajkama i mreže s takvim tipom učenja koristi se za prepoznavanje uzoraka. Za prethodno je navedene načine učenja važno je li izlazna vrijednost poznata ili nije. Prema tome određujemo koristi li se nadgledano učenje ili ne.

Osim što učenje ovisi o tome je li poznata izlazna vrijednost ili nije, važno je znati uče li se neuronske mreže pomoću iteracija ili epoha. Iteracija u učenju neuronske mreže zapravo je pomak u algoritmu u kojem se vrši podešavanje težinskih faktora. Epoha u učenju neuronske mreže predstavlja cjelokupan skup za učenje.

Grupno (*engl. batch* ili *off-line*) i pojedinačno (*engl. Pattern-By-Pattern* ili *on-line*) učenje ovisi o tome koliko se primjera za učenje pokaže mreži za vrijeme trajanja jedne iteracije. Za grupno učenje predočavaju se svi primjeri u jednoj iteraciji. Zbog toga

neuronska mreža uči u samo jednoj fazi u kojoj se prilagođavaju težine, a u ostalim fazama težine su fiksirane. Pojedinačno učenje drugačije je od grupnog. Neuronska mreža uči se u vremenskim intervalima, a u svakom vremenskom intervalu, tj. iteraciji, dodijeljen je jedan primjer za učenje neuronske mreže. Pritom se i vrši prilagodba težinskih faktora.

## **2.4. Na koji se način učenjem stvara neuronska mreža?**

Rad umjetne neuronske mreže odvija se u dvije osnovne faze: najprije se odvija faza učenja ili treniranja mreže, a zatim slijedi faza testiranja.

### **2.4.1. Faza učenja**

Učenje je proces mijenjanja težina u mreži, a odvija se kao odgovor na podatke izvana koji su predstavljeni ulaznom sloju i u nekim mrežama izlaznom sloju. Podaci koji se predstavljaju izlaznom sloju su željene vrijednosti izlaznih varijabli. Ako su one poznate, radi se o tzv. nadgledanom učenju. Kod nekih mreža željeni izlaz ne mora biti predstavljen mreži. U tom slučaju radi se o tzv. nenadgledanom učenju. Najčešći nenadgledani algoritmi su *Kohonenova mreža* i *mreža konkurentskog učenja*.

Prije samog učenja potrebno je definirati model (ulazne i izlazne varijable) te prikupiti podatke iz prošlosti na kojima će se primijeniti mreža. Prikupljene podatke treba podijeliti u dva poduzorka: uzorak za treniranje i testiranje. Ako se za vrijeme učenja planiraju koristiti optimizacijske tehnike za optimiranje duljine učenja i strukture mreže, potrebno je ukupan uzorak podijeliti na tri poduzorka (za treniranje, testiranje i konačnu validaciju). Pravila za ovu podjelu nema, osim što se preporučuje najveći dio podataka ostaviti za treniranje mreže, a manji dio podataka za testiranje i validaciju (npr. 70% za treniranje, 10% za testiranje i 20% za validaciju). Podaci se raspoređuju u poduzorke slučajno, osim kod vremenskih serija gdje treba poštovati vremenski slijed nastajanja promatranja, tj. trenirati mrežu na starijim, a testirati na novijim podacima.

Nakon što je definiran model, pripremljeni ulazni podaci i izabran NM algoritam te pravilo učenja i potrebne funkcije, mrežu treba učiti ili trenirati na pripremljenim podacima iz prošlosti kako bi ona prepoznala vezu između podataka i bila u mogućnosti na osnovi ulaznih vrijednosti predviđati izlaze. Sama faza učenja proces je podešavanja težina u mreži koji se odvija u više iteracija ili prolaza kroz mrežu. Jedna iteracija predstavlja učitavanje jednog promatranja iz podataka (jednog ulaznog i izlaznog vektora), ali se zbog povećanja brzine učenja ponekad preporučuje učitati više promatranja odjednom, pri čemu se broj promatranja koji se obrađuju u jednoj iteraciji zove epoha. U svakoj iteraciji računaju se nove težine, a kod nadgledanih algoritama i nova greška. Obično se mreža trenira u nekoliko tisuća iteracija.

Najvažnije pitanje u ovoj fazi je koliko dugo trenirati mrežu kako bi ona dala što bolji rezultat, odnosno najmanju grešku. Ne postoje pravila za dužinu treniranja te odgovor na ovo pitanje treba potražiti vlastitim eksperimentiranjem.

#### **2.4.2. Testiranje mreže**

Testiranje mreže druga je faza rada neuronske mreže i ona je odlučujuća za ocjenjivanje mreže. Razlika između faze učenja i faze testiranja je u tome što u ovoj drugoj fazi mreža više ne uči, a to znači da su težine fiksne na vrijednostima koje su dobivene kao rezultat prethodne faze učenja. Takvoj se mreži predstavljaju novi ulazni vektori koji nisu sudjelovali u procesu učenja, a od mreže se očekuje da za predstavljen novi ulazni vektor proizvede izlaz. Ocjenjivanje mreže obavlja se izračunavanjem greške ili nekog drugog mjerila točnosti, tako da se izlaz mreže uspoređuje sa stvarnim izlazima.

Dobivena greška mreže na uzorku za validaciju je rezultat kojim se tumači uspješnost ili neuspješnost neuronske mreže i njezina korisnost u primjeni za predviđanje na budućim podacima.

## 2.5. ANFIS (engl. adaptive neuro - fuzzy inference system) neuronska mreža

U prethodnim poglavljima govori se o *fuzzy* logici i neuronskim mrežama, a u ovom poglavlju će se govoriti o ANFIS-u. ANFIS (engl. adaptive neuro fuzzy inference system ) je alat unutar *Matlaba* koji učenjem spaja *fuzzy* logiku i neuronske mreže u jednu cjelinu. Neuronska mreža u ANFIS sustavu istovremeno postaje i *fuzzy* sustav za zaključivanje.

ANFIS se može predstaviti kao struktura adaptivne neuronske mreže sastavljena od pet slojeva koja svojom funkcionalnošću odgovara *fuzzy* modelu *Sugeno*.

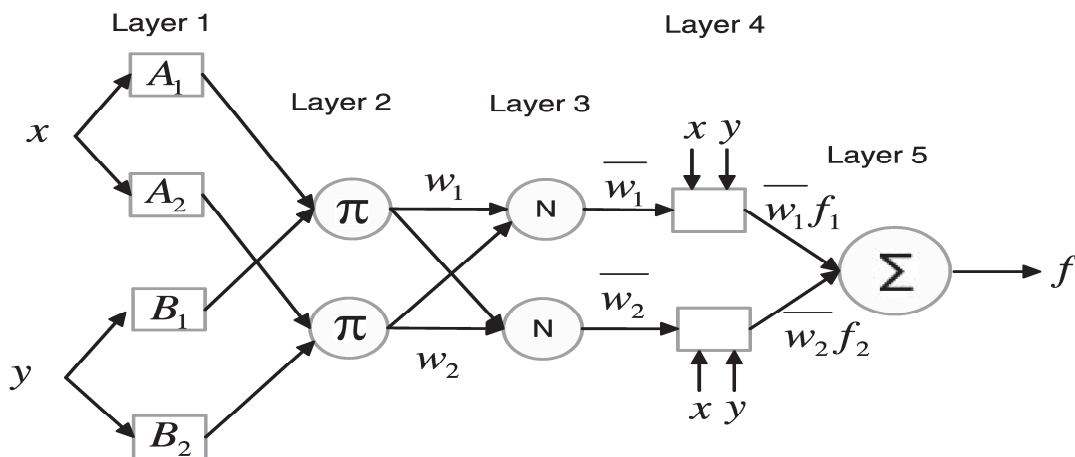
Za opis strukture koristi se sistem s 2 ulaza  $x$  i  $y$  i jednim izlazom  $z$ . Za *Sugeno* model prvog reda najčešće se definiraju dva pravila sljedećeg oblika:

ako  $x$  je  $A_1$  I  $y$  je  $B_1$  onda  $f_1 = p_1x + q_1y + r_1$

ako  $x$  je  $A_2$  I  $y$  je  $B_2$  onda  $f_2 = p_2x + q_2y + r_2$

$p_i, q_i, r_i$  - parametri zaključka pravila

Slika 7. Struktura ANFIS-a



Izvor: [http://www.lejla-bm.com.ba/IU/IU\\_10.pdf](http://www.lejla-bm.com.ba/IU/IU_10.pdf)

### **1. sloj –ulazni sloj**

### **2. sloj – Funkcija pripadnosti ulaza**

- fuzifikacija
- aktivacijska funkcija fuzifikacijskog neurona odgovara neizrazitom skupu pridruženom pravilu

### **3. sloj – neizrazita pravila**

- svaki neuron odgovara neizrazitom pravilu
- konjunkcija (min) ulaza (AKO dijela) pravila se kod neizrazitih skupova ostvaruje operacijom presjeka (množenja)

Težine između 3. i 4. sloja odgovaraju normaliziranim stupnjevima (faktorima) uvjerenosti u istinitost neizrazitih pravila

- težine se uspostavljaju u fazi učenja sustava

### **4. sloj – funkcije pripadnosti izlaza**

- disjunkcija (max) izlaza (ONDA dijela) pravila se kod neizrazitih skupova ostvaruje operacijom unije (algebarskog zbroja)

### **5. sloj – defazifikacija**

- metode defazifikacije (slaganje zbroja i umnoška)



### **3. MODELIRANJE INTELIGENTNOG SUSTAVA**

#### **3.1. Predprocesiranje**

Podaci su prikupljeni na temelju državne mature i upisa studenata na Međimursko veleučilište u Čakovcu. Zbog poboljšanja kvalitete podataka za daljnju analizu i obradu obavljeno je predprocesiranje. Kod prikupljenih podataka može se zamijetiti veliko odstupanje od minimalne i maksimalne vrijednosti zbog čega je potrebno napraviti normalizaciju podataka. Formula po kojoj će se provesti normalizacija je:

$$y' = \frac{y - \min}{\max - \min}$$

gdje je:

$y'$  - nova normalizirana vrijednost

$y$  - trenutna stvarna vrijednost koju je potrebno normalizirati

$\min$  - minimalna vrijednost navedenog atributa

$\max$  - maksimalna vrijednost navedenog atributa

Slika 8. Tablica s izvornim podacima

| Početni p | Izbor | Bodovi iz škole | Bodovi dr. Matur | Bodovi ukupno |
|-----------|-------|-----------------|------------------|---------------|
| 1         | 1     | 415             | 280,4700012      | 787,3         |
| 4         | 1     | 477             | 310,3099976      | 780,3         |
| 6         | 1     | 447             | 333,25           | 773,3         |
| 10        | 1     | 487             | 308,25           | 762,1         |
| 11        | 1     | 489             | 293,1300049      | 742,1         |
| 14        | 1     | 480             | 282,0599976      | 732,9         |
| 16        | 1     | 450             | 282,9400024      | 730,9         |
| 17        | 1     | 487             | 283,9100037      | 728,8         |
| 21        | 1     | 478             | 250,7799988      | 708,8         |
| 26        | 1     | 461             | 247,8099976      | 708,2         |
| 28        | 1     | 370             | 338,1900024      | 704,4         |
| 29        | 1     | 409             | 295,3800049      | 696,5         |
| 32        | 1     | 481             | 215,4700012      | 693,3         |
| 35        | 1     | 378             | 315,3099976      | 692,9         |
| 36        | 1     | 393             | 299,9400024      | 692,2         |
| 37        | 1     | 470             | 222,1799927      | 690,1         |
| 40        | 1     | 478             | 214,0599976      | 685,9         |
| 44        | 2     | 414             | 271,8899951      | 683,2         |
| 47        | 1     | 398             | 285,1800037      | 680,9         |
| 49        | 1     | 444             | 238,8800049      | 677,2         |
| 52        | 1     | 422             | 255,1800037      | 670           |
| 58        | 1     | 422             | 247,9700012      | 662,9         |
| 62        | 1     | 412             | 250,8800049      | 661,5         |
| 64        | 1     | 437             | 224,5299988      | 654,3         |
| 72        | 1     | 389             | 285,3099976      | 654,1         |
| 73        | 1     | 398             | 258,1000081      | 654           |
| 74        | 1     | 398             | 258              | 653,8         |
| 75        | 1     | 388             | 267,8099976      | 652,2         |
| 77        | 1     | 378             | 278,1900024      | 650,4         |
| 78        | 2     | 395             | 255,4400024      | 650           |
| 79        | 1     | 421             | 229              | 648,9         |
| 81        | 1     | 413             | 235,9400024      | 645,9         |
| 83        | 1     | 359             | 288,8899951      | 644,3         |
| 85        | 1     | 389             | 255,3099976      | 643,9         |
| 86        | 2     | 424             | 219,8500081      | 643,4         |
| 88        | 1     | 328             | 315,4400024      | 637,6         |
| 96        | 1     | 411             | 228,5599976      | 637           |
| 97        | 1     | 410             | 228,0000045      | 634,0         |

Izvor: Autor

Slika 9. Tablica s normaliziranim podacima

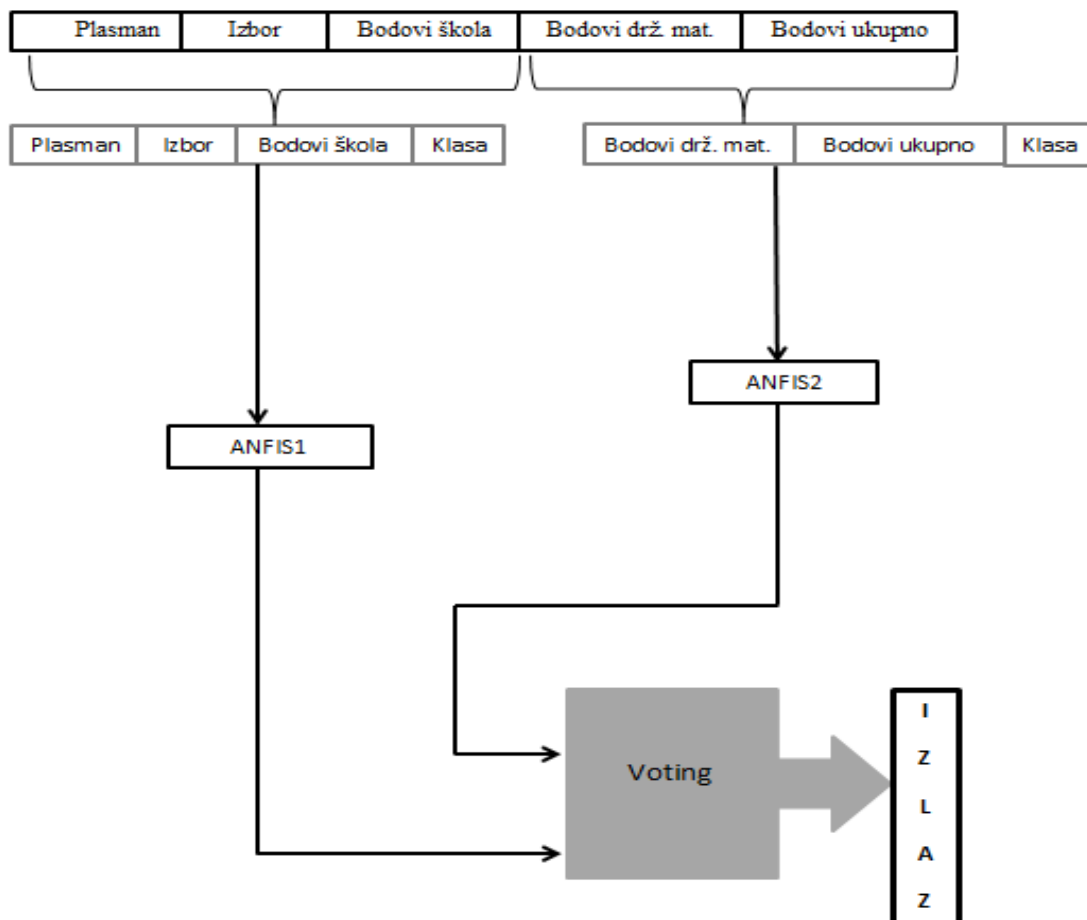
| Plasman2   | Izbor2 | Bodovi iz škole2 | Bodovi dr. Matura2 | Bodovi ukupno2 |
|------------|--------|------------------|--------------------|----------------|
| 0          | 0      | 0,691588785      | 0,781746155        | 1              |
| 0,01694915 | 0      | 0,981308411      | 0,931330465        | 0,984923541    |
| 0,03389831 | 0      | 0,841121495      | 1,000180077        | 0,969847082    |
| 0,05084746 | 0      | 0,934579439      | 0,919145232        | 0,945724747    |
| 0,06779661 | 0      | 0,943925234      | 0,879768315        | 0,902649149    |
| 0,08474576 | 0      | 0,901869159      | 0,846544007        | 0,882834374    |
| 0,10169492 | 0      | 0,855140187      | 0,849185157        | 0,878526815    |
| 0,11864407 | 0      | 0,934579439      | 0,792070601        | 0,869696317    |
| 0,13559322 | 0      | 0,976635514      | 0,752663642        | 0,830928279    |
| 0,15254237 | 0      | 0,906542056      | 0,743749805        | 0,825328451    |
| 0,16949153 | 0      | 0,481308411      | 1,009003879        | 0,821451648    |
| 0,18644068 | 0      | 0,663551402      | 0,886521219        | 0,804436787    |
| 0,20338983 | 0      | 1                | 0,64668808         | 0,797544691    |
| 0,22033898 | 0      | 0,518691589      | 0,946336918        | 0,796683179    |
| 0,23728814 | 0      | 0,588785047      | 0,900207096        | 0,795175533    |
| 0,25423729 | 0      | 0,948598131      | 0,666826714        | 0,790652595    |
| 0,27118644 | 0      | 0,976635514      | 0,642456249        | 0,78160672     |
| 0,28813559 | 0,125  | 0,686915888      | 0,815960849        | 0,775791514    |
| 0,30508475 | 0      | 0,612149533      | 0,855848026        | 0,77083782     |
| 0,3220339  | 0      | 0,827102804      | 0,710945721        | 0,762868835    |
| 0,33898305 | 0      | 0,724299065      | 0,765809309        | 0,74736162     |
| 0,3559322  | 0      | 0,724299065      | 0,744230023        | 0,732069782    |
| 0,37288136 | 0      | 0,677570093      | 0,752963789        | 0,729054491    |
| 0,38983051 | 0      | 0,794392523      | 0,673879765        | 0,713547275    |
| 0,40677966 | 0      | 0,570093458      | 0,79627239         | 0,713116519    |
| 0,42372881 | 0      | 0,612149533      | 0,768630529        | 0,712901142    |
| 0,44067797 | 0      | 0,602803738      | 0,774332963        | 0,712470386    |
| 0,45762712 | 0      | 0,556074766      | 0,803775616        | 0,709024338    |
| 0,47457627 | 0      | 0,509345794      | 0,828926446        | 0,705147534    |
| 0,49152542 | 0,125  | 0,598130841      | 0,766649667        | 0,704286022    |
| 0,50847458 | 0      | 0,719626168      | 0,687295537        | 0,701916864    |
| 0,52542373 | 0      | 0,682242991      | 0,708124501        | 0,695455524    |
| 0,54237288 | 0      | 0,429906542      | 0,860980207        | 0,692009477    |
| 0,55932203 | 0      | 0,570093458      | 0,766259484        | 0,691147965    |
| 0,57627119 | 0,125  | 0,73364486       | 0,659833747        | 0,690071075    |
| 0,59322034 | 0      | 0,285046729      | 0,9467271          | 0,677579151    |
| 0,61016949 | 0      | 0,672897196      | 0,679972381        | 0,676286883    |

Izvor: Autor

### 3.2. Modeliranje ANFIS-a

Nakon predprocesiranja slijedi modeliranje s ANFIS-om. Prikupljeni podaci se dijele na skupove za učenje, tj. treniranje i testiranje. Od ukupno 191 podatka za treniranje i testiranje, 134 se koristi za treniranje, a preostalih 38 za testiranje. U cilju razbijanja kompleksne višedimenzionalne strukture podataka u manje dimenzionalnu strukturu, obavljena je segmentacija podataka. S obzirom na 5 ulaznih atributa segmentacija je obavljena na osnovu 2 ulazne varijable, tako su kreirana 2 FIS-a, koja su poslužila za treniranje i provjeru modela. Način na koji se informacije spajaju u jednu i kao rezultat daju jednu izlaznu vrijednost predstavljeno je na slici 10. Vrijednost varijable na izlazu određuje se putem glasovanja (*engl. votinga*).

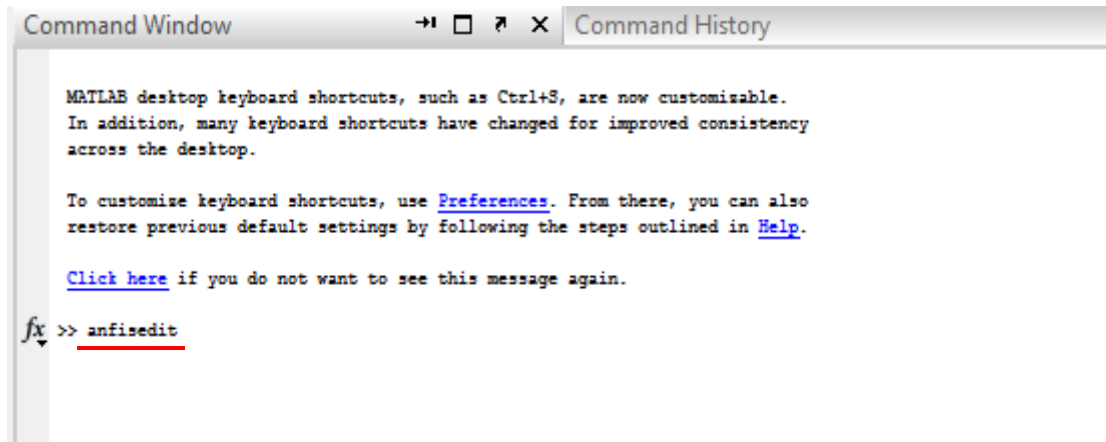
Slika 10. Parcijalno modeliranje podataka



Izvor: Autor

Da bi se pokrenuo ANFIS *editor* GUI potrebno je u komandni prozor *Matlaba* upisati *anfisedit*, slika 11.

Slika 11. Komandni prozor



Izvor: Autor

Prozor ANFIS *editor* GUI-a dijeli se na nekoliko cjelina koje će poslužiti pri svakom od parcijalnog modeliranja adaptivno *neuro-fuzzy* sistema zaključivanja od ANFIS1-ANFIS2.

Prije samog treniranja potrebno je:

**1) Učitati skup podataka koji sadrži ulazno/izlaze podatke sistema koji se modelira**

Skup podataka koji se učitava mora biti niz uzoraka uređenih kao vektori stupaca s izlaznim podacima u zadnjem stupcu.

**2) Odrediti i učitati početnu strukturu modela (strukturu *Sugeno*)**

U ovom će se slučaju koristiti **Grid partiton** – generira FIS *Sugeno* tipa s jednim izlazom korištenjem mrežne podjele podataka.

**3) Odabrati metodu optimizacije *hybrid* ili *backpropaga***

Metode optimizacije treniraju parametre funkcije pripadnosti da bi imitirali podatke za treniranje. Metoda optimizacije *hybrid* je kombinacija metode najmanjih kvadrata i metode *backpropagation* gradijentnog pada.

**4) Upisati broj epoha za treniranje *Epochs* i toleranciju greške *Error Tolerance* da bi se podesio zaustavni kriterij za treniranje**

Proces treniranja zaustavlja se kad se dostigne maksimalan broj epoha ili kad se dostigne cilj treniranja.

Kad se sve od navedenog odredi, može započeti treniranje mreže. Podaci se grafički iscrtavaju.

Nakon treniranja FIS-a, model se validira korištenjem podataka za testiranje i provjeru koji se razlikuju od podataka koji su korišteni za treniranje FIS-a.

Podaci za treniranje, testiranje i provjeru predstavljeni su različitim oznakama: podaci za treniranje – KRUG, za testiranje – DIJAMANTI, a za provjeru – PLUSEVI.

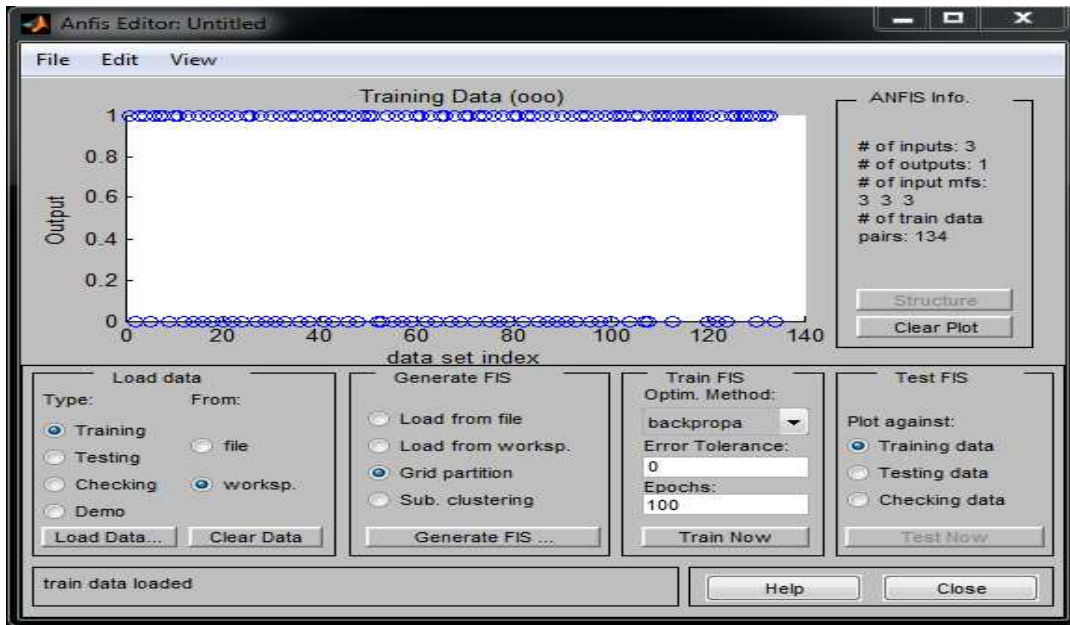


### 3.2.1. Modeliranje ANFIS 1

Za modeliranje ANFIS 1 upotrijebljene su normalizirane vrijednosti prvih triju atributa (plasman, izbor, bodovi iz škole).

Nakon upisa *anfisedit*, u komandnom prozoru *Matlaba* pojavit će se ANFIS editor (slika 12.).

Slika 12. ANFIS editor

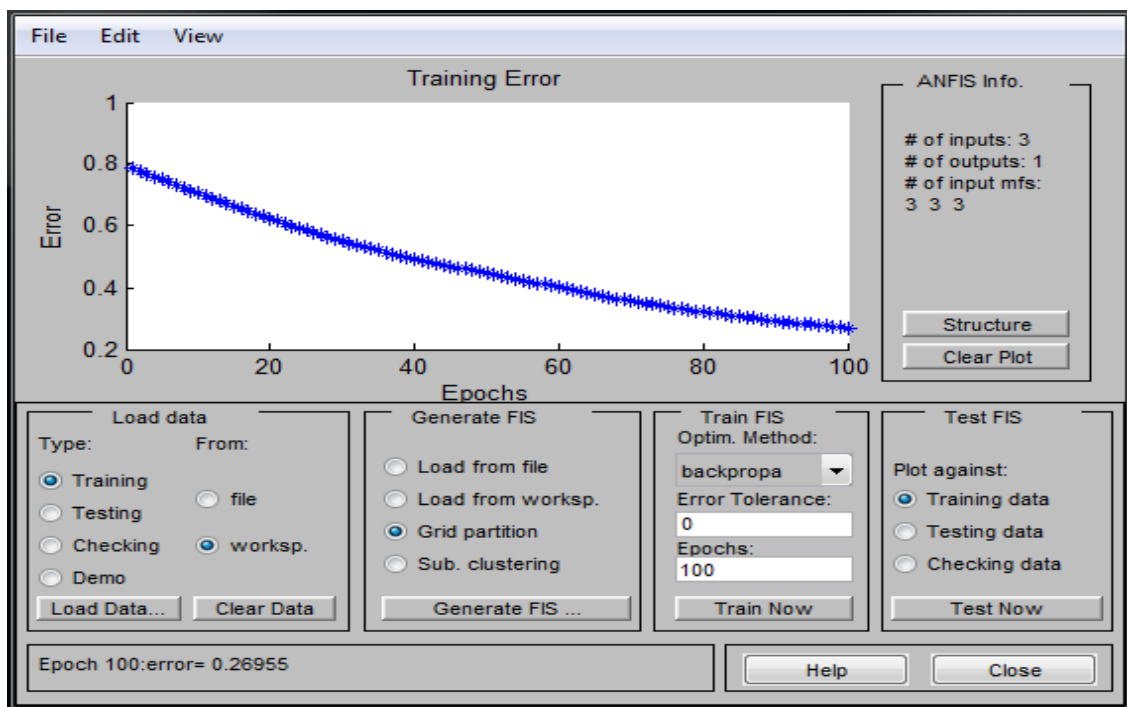


Izvor: Autor

Sljedeći korak je generiranje FIS strukture, nakon čega se pristupa treniranju FIS-a s različitim opcijama generiranja i načinom optimizacije.

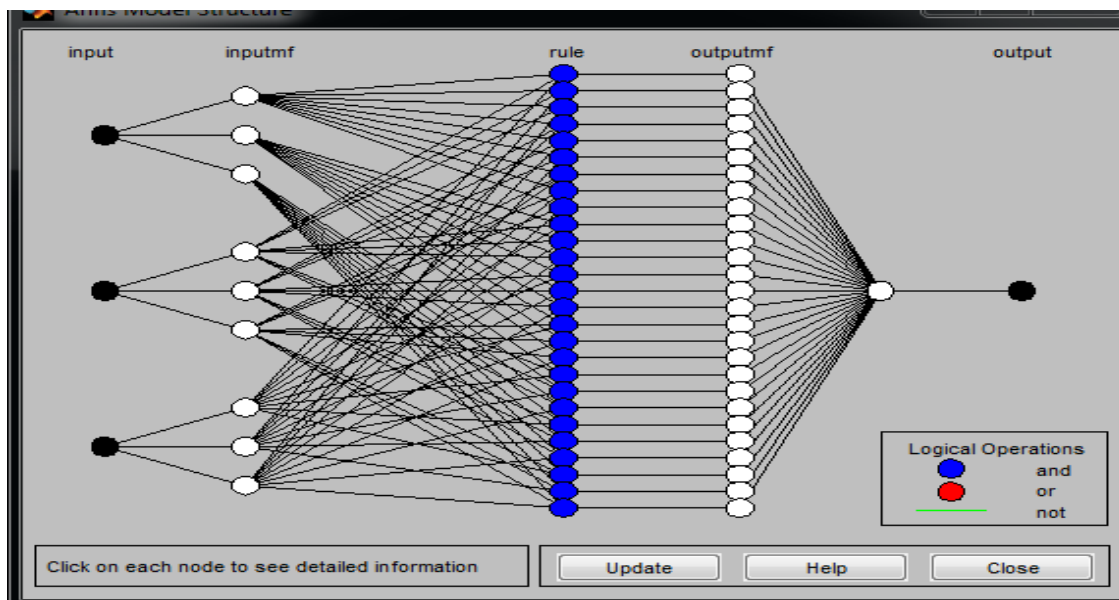
U nastavku su prezentirani rezultati za odabranu FIS strukturu. Zbog malog broja uzoraka, broj epoha za sve slučajeve ostao je isti jer nije bitno utjecao na grešku.

Slika 13. Greška treniranja za odabranu FIS strukturu s najmanjom greškom



Izvor: Autor

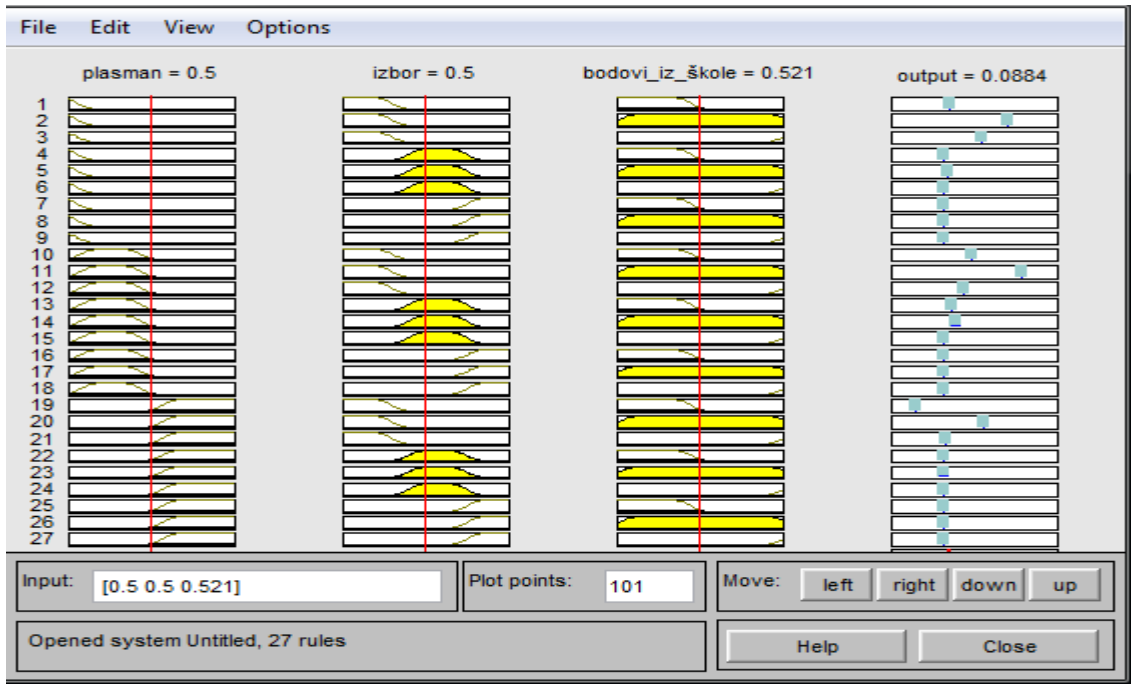
Slika 14. Struktura ANFIS mreže za odabrani FIS



Izvor: Autor

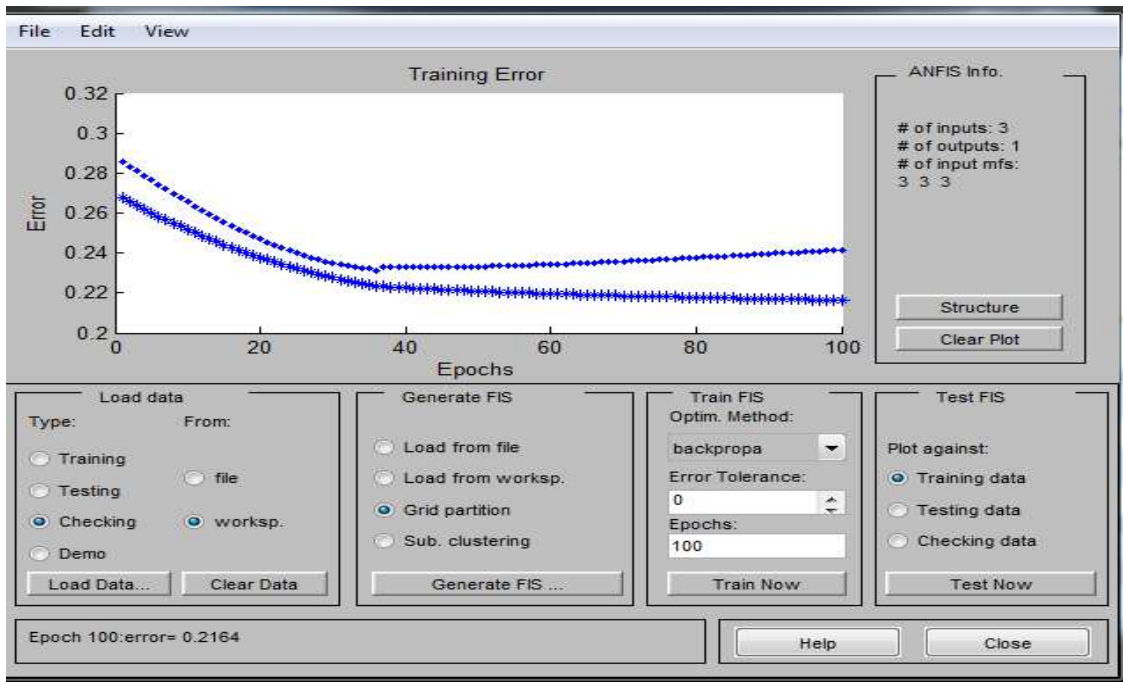


Slika 15. Baza znanja za odabrani model



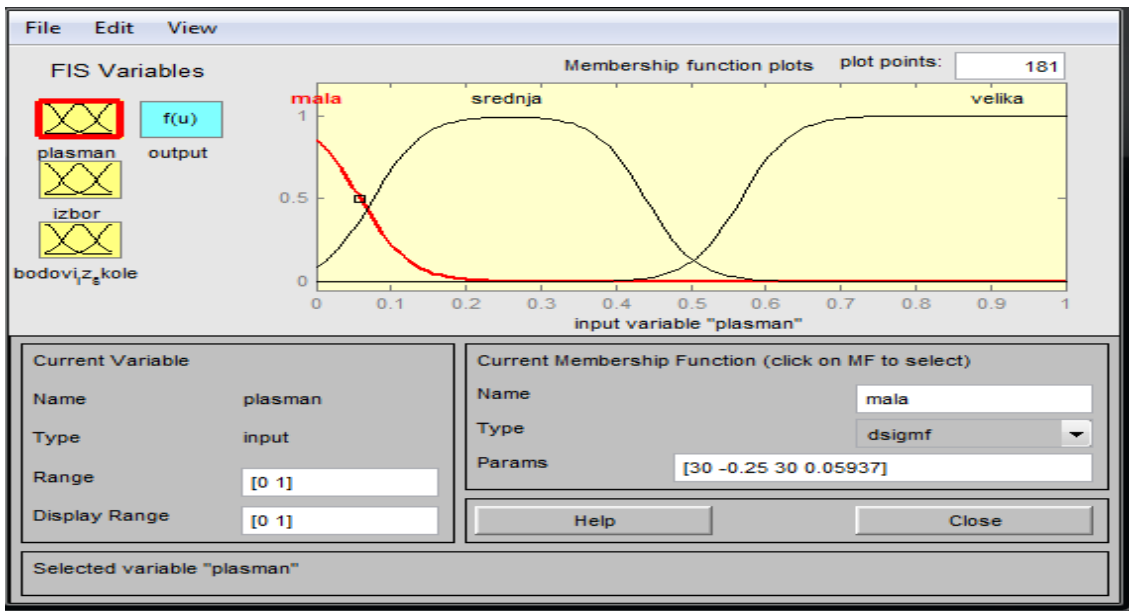
Izvor: Autor

Slika 16. Greška treniranja za odabranu FIS strukturu s najmanjom greškom



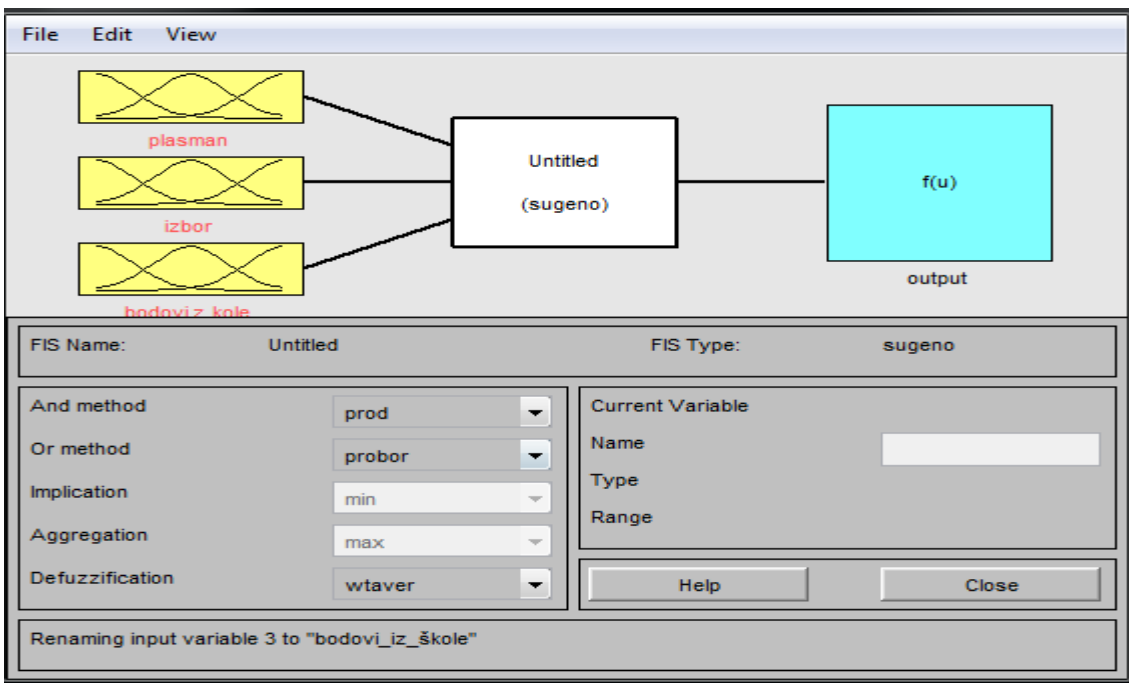
Izvor: Autor

Slika 17. Greška treniranja za odabranu FIS strukturu s najmanjom greškom



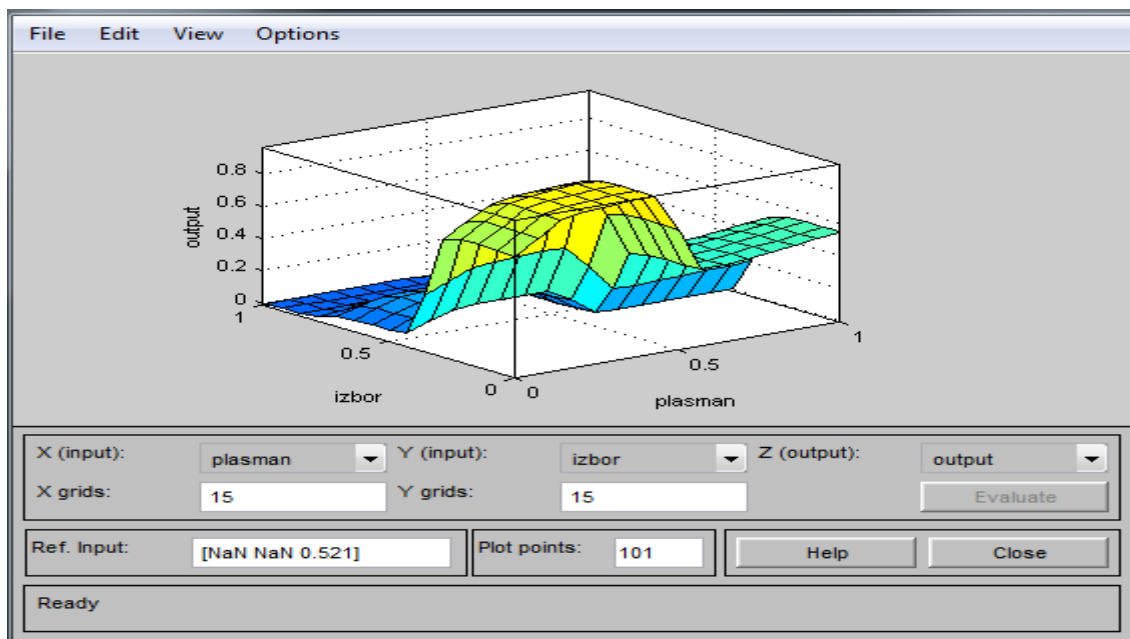
Izvor: Autor

Slika 18. Editor za FIS strukturu



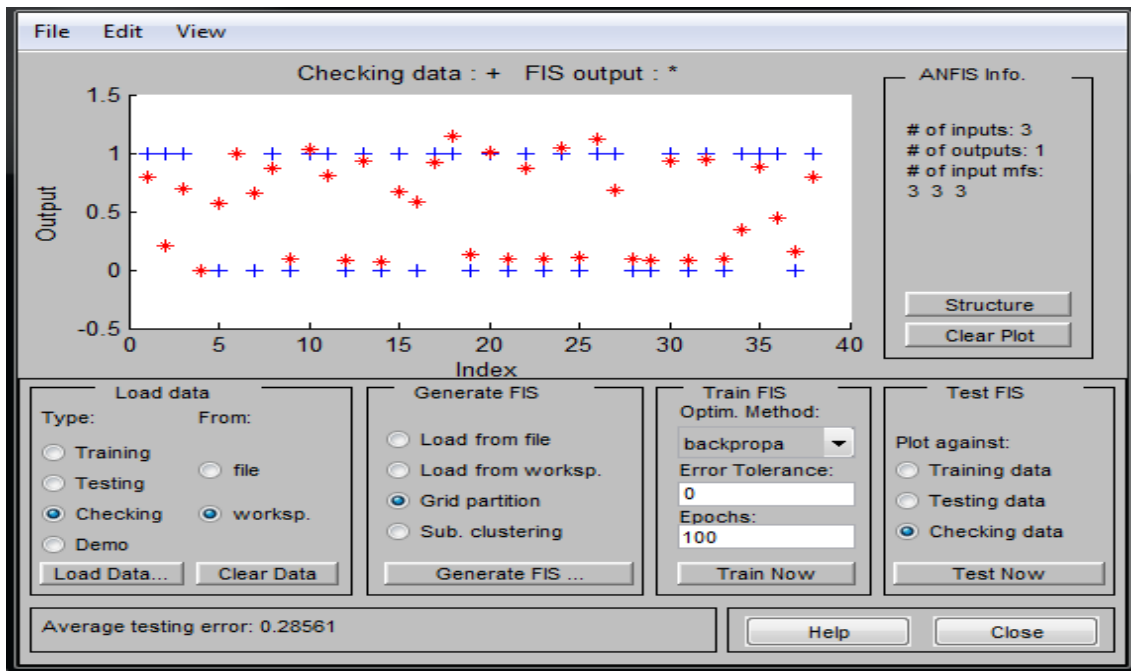
Izvor: Autor

Slika 19. Grafički prikaz



Izvor: Autor

Slika 20. Testiranje treniranog FIS-a na podatke za provjeru



Izvor: Autor

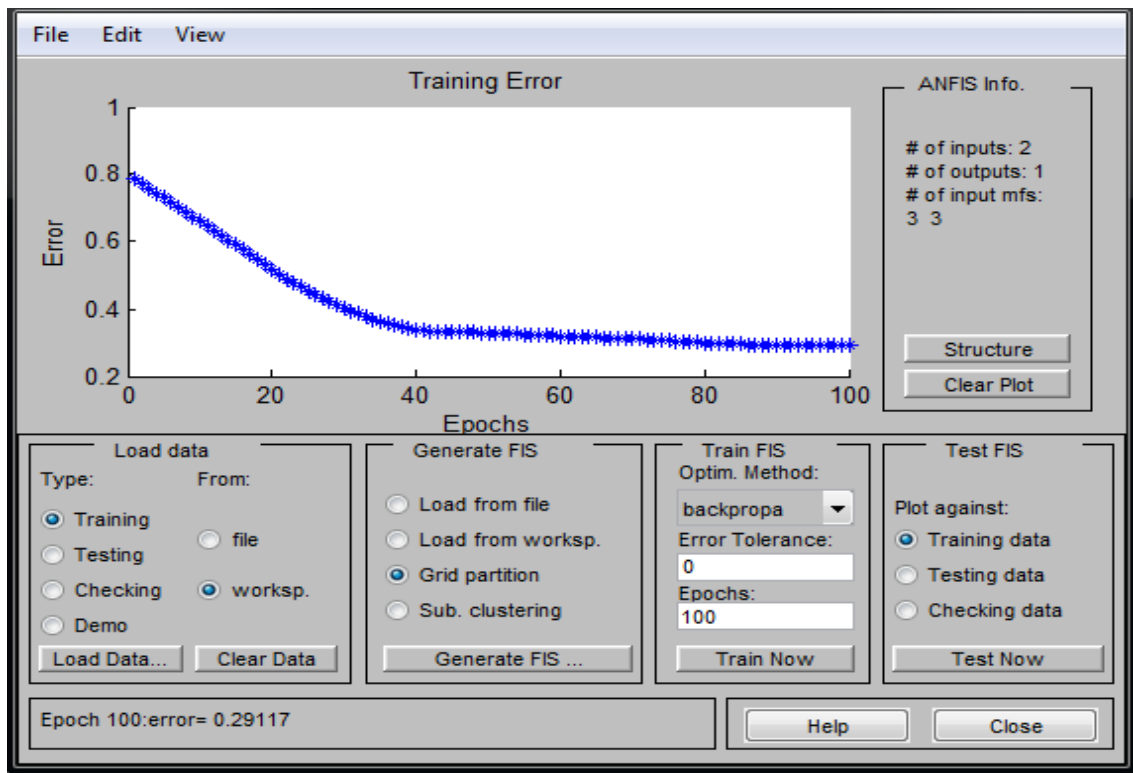
Trenirani FIS testira se podacima za provjeru (slika 20.). Na dijagramu se indicira da ne postoji veliko odstupanje između izlaza podataka za provjeru i FIS izlaza. Odabrani model zadovoljava potrebe.

### 3.2.2. Modeliranje ANFIS2

Za modeliranje ANFIS 2 upotrijebljene su normalizirane vrijednosti dvaju atributa (bodovi državna matura i bodovi ukupno). Postupak je identičan kao i u prethodnom slučaju.

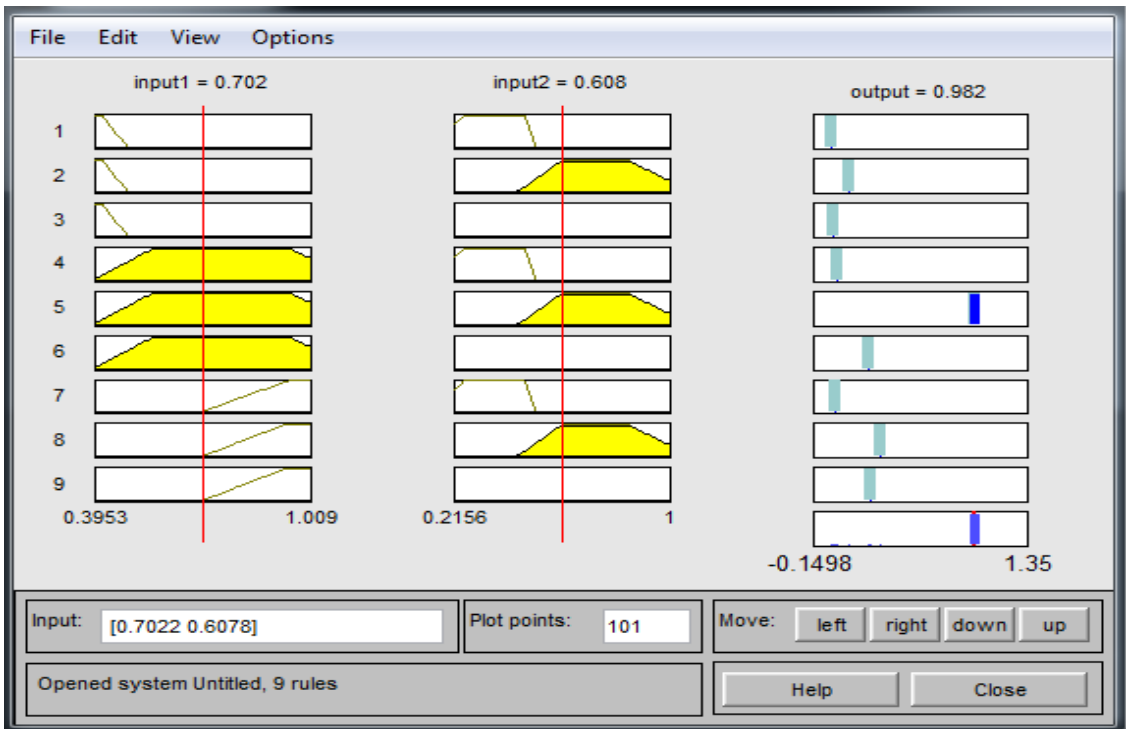
Broj epoha je i u drugom slučaju ostao isti jer nije bitno utjecao na rezultat pogreške.

Slika 21. Greška treniranja za odabranu FIS strukturu s najmanjom greškom



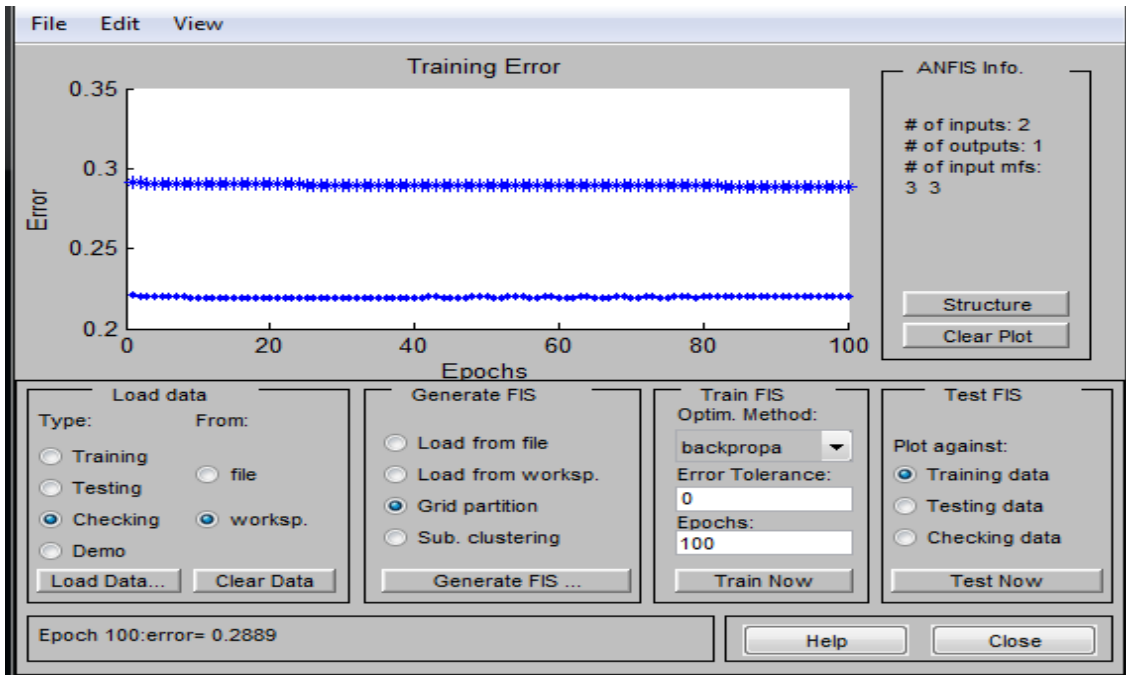
Izvor: Autor

Slika 22. Baza znanja za odabrani model



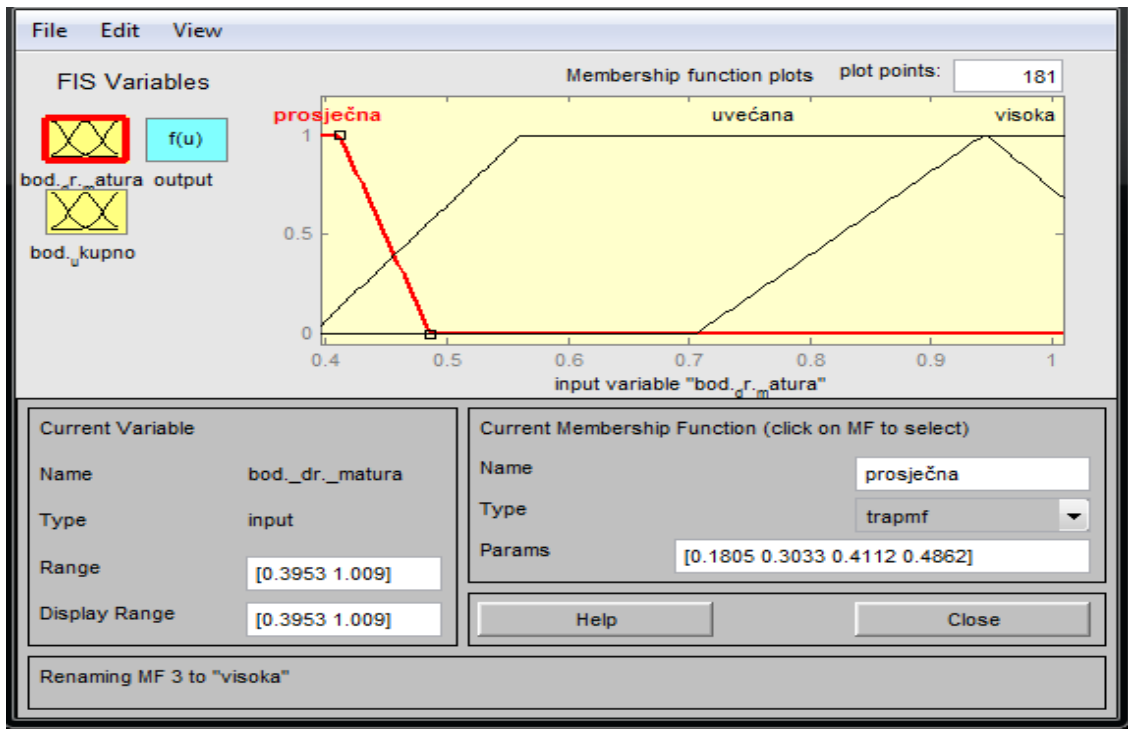
zvor: Autor

Slika 23. Greška treniranja za odabranu FIS strukturu s najmanjom greškom



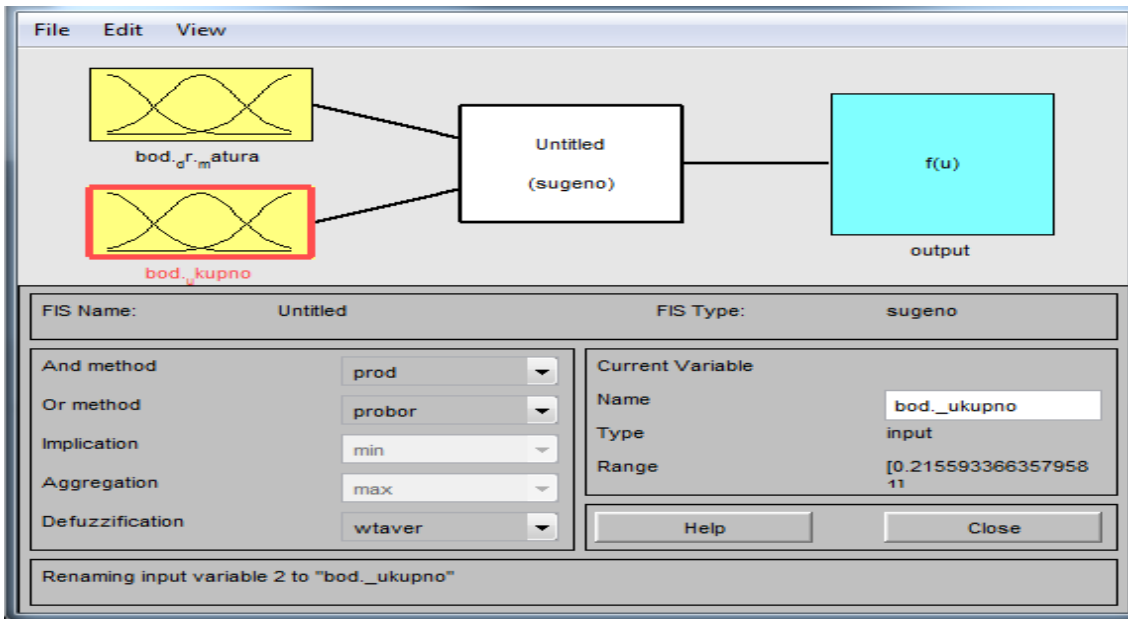
Izvor: Autor

Slika 24. Greška treniranja za odabranu FIS strukturu s najmanjom greškom



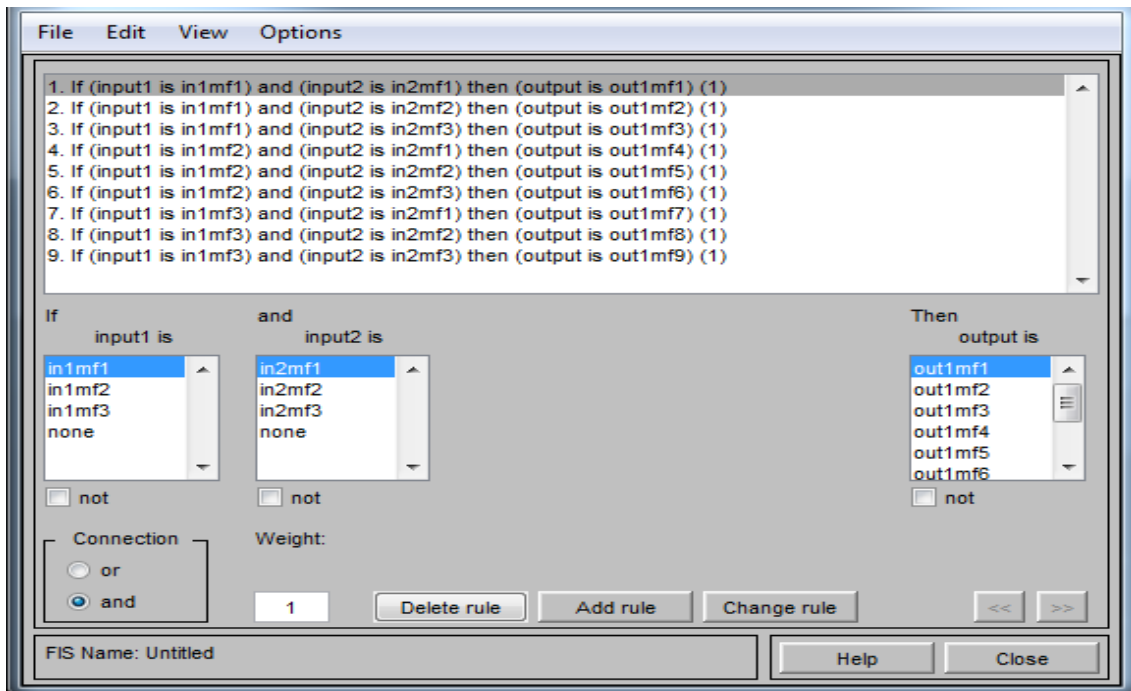
Izvor: Autor

Slika 25. Editor za FIS strukturu



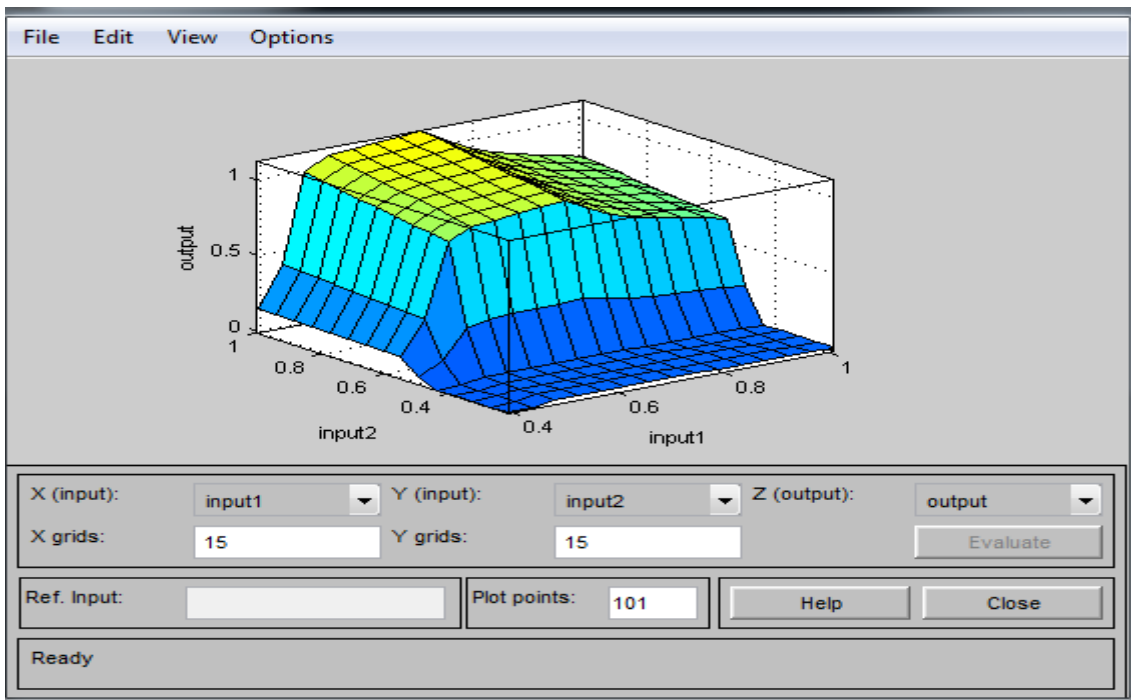
Izvor: Autor

Slika 26. Editor pravila za odabrani model



Izvor: Autor

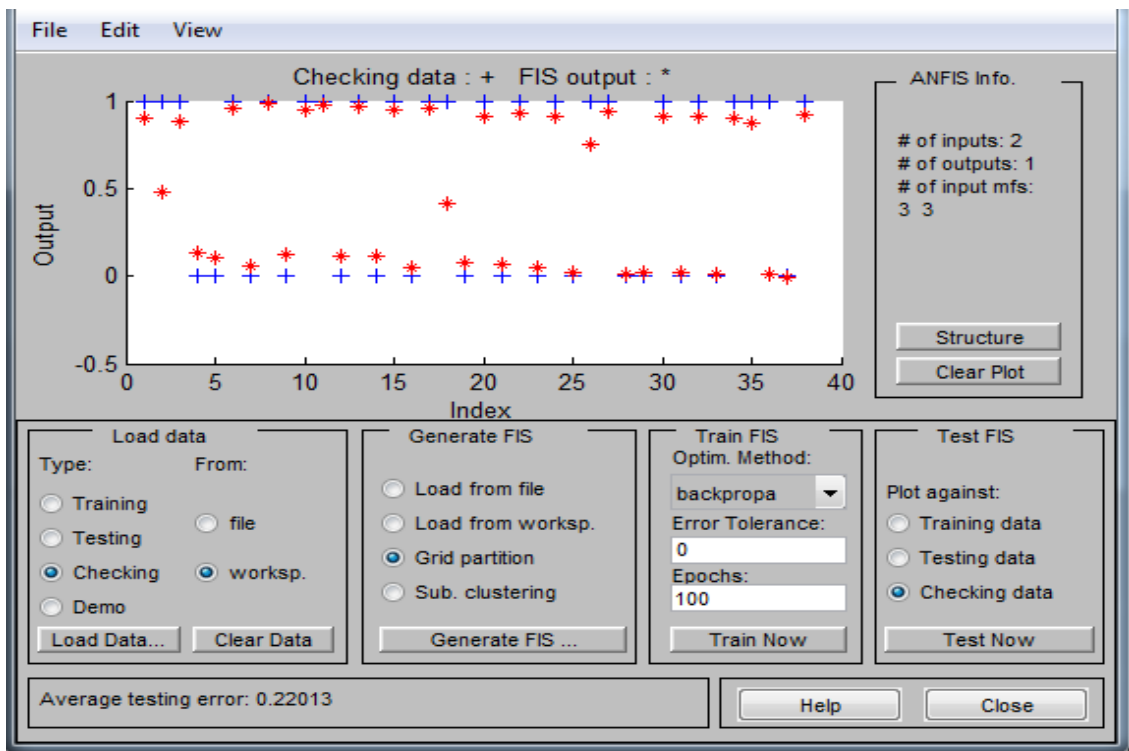
Slika 27. Grafički prikaz odabranog FIS modela



Izvor: Autor



Slika 28. Testiranje treniranog FIS-a na podatke za provjeru



Izvor: Autor

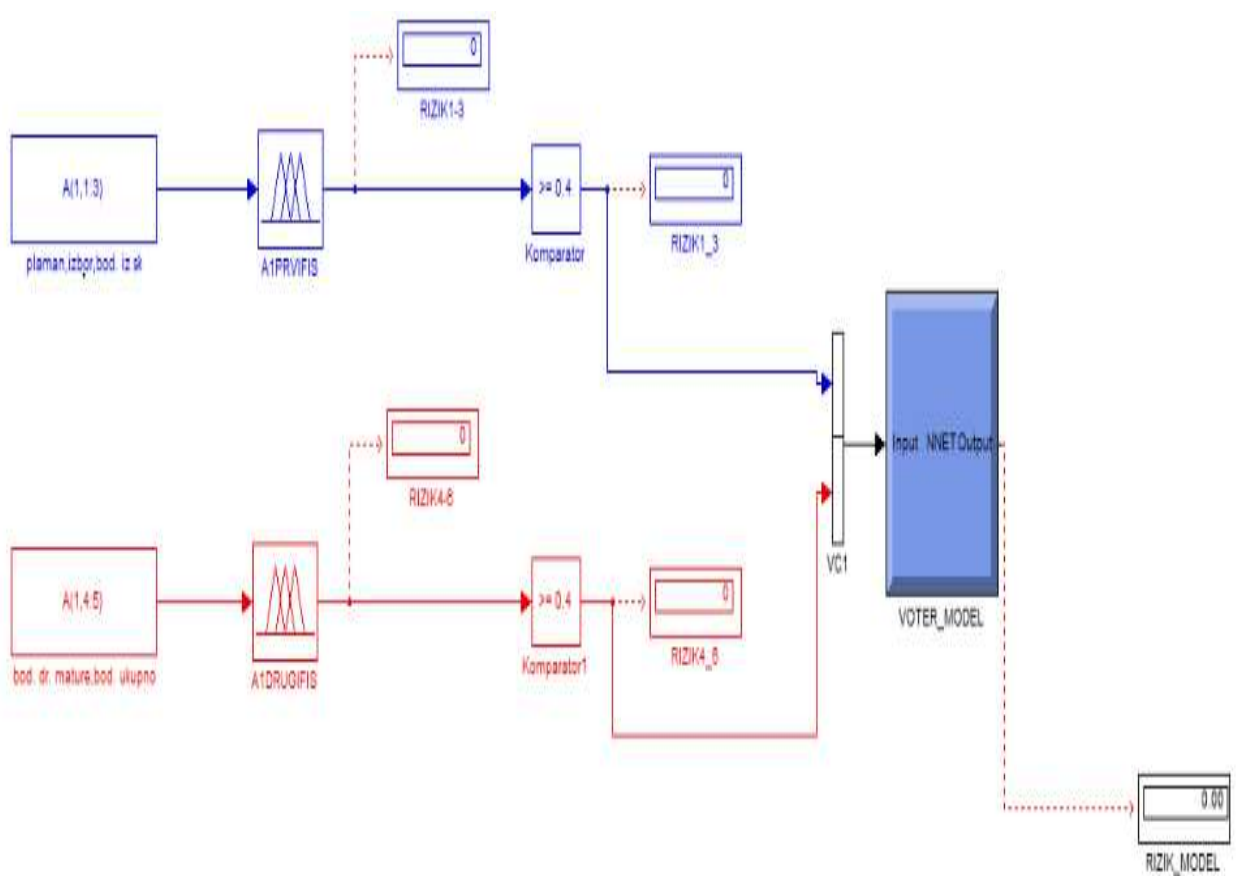
Trenirani FIS testira se podacima za provjeru (slika 28.). Na dijagramu se indicira da ne postoji veliko odstupanje između izlaza podataka za provjeru i FIS izlaza. Odabrani model zadovoljava potrebe.

#### 4. SIMULACIJA

U *simulinku* je izrađena simulacija inteligentnog sustava kojom je prikazana funkcionalnost samog sustava. Inteligentan sustav sastoji se od ANFIS mreže (fis1 i fis2), ulaznih varijabli, konvertora, komparatora, vektora i voter\_modela (slika 29.).

Za simulaciju se koristi najbolja neuronska mreža. Nakon provjere, dobiveni rezultati potvrđuju da odabrana neuronska mreža u potpunosti odgovara zahtjevima ovog rada.

Slika 29. Simulink model za ANFIS



Izvor: Autor

## **5. ZAKLJUČAK**

Ovim završnim radom predstavljena je izrada inteligentnog sustava za klasifikaciju studenata kod kojih postoji rizik od prekida studiranja na Međimurskom veleučilištu. Sintezom *fuzzy* logike i neuronske mreže dobiven je hibridni model ANFIS(*engl.adaptive neuro-fuzzy inference system*). Generiranjem i modeliranjem dan je inteligentni sustav za klasifikaciju.

Obradom prikupljenih podataka na osnovu državne mature i upisa na Međimursko veleučilište u Čakovcu, kroz filtraciju i normalizaciju te odabirom najprikladnijih atributa za generiranje i modeliranje putem ANFIS-a, stvoreno je previše neinterpretativnih pravila. Provedenim istraživanjem za objektiviziranu klasifikaciju studenata kod kojih postoji rizik od prekida studiranja na Međimurskom veleučilištu, traži se najprikladnija metoda unutar inteligentnog sustava za zadani uzorak podataka.

Unatoč malom broju podataka, simulacijom i rezultatima simulacije dokazano je da odabrani model za klasifikaciju, modeliran sa zadanim uzorkom podataka i brojem atributa udovoljava klasifikaciji studenata kod kojih postoji rizik od prekida studiranja na Međimurskom veleučilištu.

Za potpuniju i kvalitetniju procjenu rizika od prekida studiranja potrebno je imati na raspolaganju veći broj uzoraka, a s tim i veći broj atributa kako bi model bio reprezentativniji pridonosenju odluke.

## **6. LITERATURA**

[1] prof.dr.sc. Bojana Dalbelo Bašić, mr.sc. Marko Čupić, mr.sc. Jan Šnajder, Umjetne neuronske mreže, FER, Zagreb, 2008

[2] [https://www.fer.unizg.hr/predmet/neumre\\_a/predavanja](https://www.fer.unizg.hr/predmet/neumre_a/predavanja)

[3] [https://www.fer.unizg.hr/\\_download/repository/ISU\\_all.pdf](https://www.fer.unizg.hr/_download/repository/ISU_all.pdf)

[4] [https://bib.irb.hr/datoteka/285069.Diplomski\\_rad\\_1533.pdf](https://bib.irb.hr/datoteka/285069.Diplomski_rad_1533.pdf)

[5] [http://www.fer.unizg.hr/\\_download/repository/UI\\_12\\_UmjetneNeuronskeMreze.pdf](http://www.fer.unizg.hr/_download/repository/UI_12_UmjetneNeuronskeMreze.pdf)

[6] [http://nastava.fpmoz.ba/nastava/diplomski/fpmoz\\_diplomski\\_informatika\\_matic.pdf](http://nastava.fpmoz.ba/nastava/diplomski/fpmoz_diplomski_informatika_matic.pdf)

[7] <http://zrno.fsb.hr/katedra/download/materijali/1306.pdf>

[8] <http://java.zemris.fer.hr/nastava/nenr/knjiga-0.1.2012-01-05.pdf>

[9] prezentacija H. Bevrani, Membership function and fuzzification

[10] Haykin, S.: Neural Networks: a comprehensive foundation, 2nd edn (1998)

[11] Martin Gregurić, Inteligentno upravljanje priljevnim tokovima auto-ceste sa osvrtom na mogućnost primjene na zagrebačkoj zaobilaznici

[http://www.unizg.hr/rektorova/upload\\_2011/rek\\_rad\\_martin\\_greguric.pdf](http://www.unizg.hr/rektorova/upload_2011/rek_rad_martin_greguric.pdf)

[12] Prof. dr. sc. Stjepan Bogda, Ivica Draganjac, Alan Mutka, Osnove inteligentnog upravljanja, Neizravno upravljanje sustavima,

[http://www.fer.unizg.hr/\\_download/repository/OIU\\_fuzzy\\_1.pdf](http://www.fer.unizg.hr/_download/repository/OIU_fuzzy_1.pdf)

[13] Scribd, Kratak uvod u fuzzy logiku i upravljanje

<http://www.scribd.com/doc/81309187/Fuzzy>