

Primjena neuronskih mreža za predviđanje ekonomskog rasta

Cindrić, Mateo

Master's thesis / Diplomski rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics / Sveučilište u Zagrebu, Fakultet organizacije i informatike**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:211:145485>

Rights / Prava: [Attribution-NonCommercial-NoDerivs 3.0 Unported / Imenovanje-Nekomercijalno-Bez prerađivanja 3.0](#)

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



Repository / Repozitorij:

[Faculty of Organization and Informatics - Digital Repository](#)



**SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN**

Mateo Cindrić

**PRIMJENA NEURONSKIH MREŽA ZA
PREDVIĐANJE EKONOMSKOG RASTA**

DIPLOMSKI RAD

Varaždin, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Mateo Cindrić

Matični broj: 45277/16-R

Studij: *Baze podataka i baze znanja*

**PRIMJENA NEURONSKIH MREŽA ZA PREDVIĐANJE
EKONOMSKOG RASTA**

DIPLOMSKI RAD

Mentorica:

Doc. dr. sc. Dijana Oreški

Varaždin, srpanj 2018.

Mateo Cindrić

Izjava o izvornosti

Izjavljujem da je moj diplomski rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristio drugim izvorima osim onima koji su u njemu navedeni. Za izradu rada su korištene etički prikladne i prihvatljive metode i tehnike rada.

Autor potvrdio prihvaćanjem odredbi u sustavu FOI-radovi

Sažetak

Svrha rada je razviti model neuronskih mreža te analizirati čimbenike koji utječu na BDP, odnosno predvidjeti ekonomski rast Republike Hrvatske. BDP je danas vrlo važan makroekonomski pokazatelj kojim se bavi veliki broj stručnjaka i institucija. Metodološka osnova za predviđanje je metoda rudarenja podataka, odnosno umjetna neuronska mreža koja ima primjenu u rješavanju brojnih problema visokog stupnja složenosti. U radu se koristi javno dostupan skup podataka koji se priprema i modelira neuronskim mrežama. Alat korišten za obradu i analizu podataka pri čemu se koristi modeliranje neuronskih mreža je JMP 13. U teorijskom dijelu opisuje se pristup neuralnog računarstva. Objašnjava se razlika i povezanost biološke i umjetne neuronske mreže, navode se osobitosti te proces stvaranja umjetne neuronske mreže.

Ključne riječi: neuronske mreže; strojno učenje; ekonomski rast; BDP; umjetna inteligencija; perceptron

Sadržaj

1. Uvod	2
2. Neuronske mreže	3
2.1. Razlika biološke i umjetne neuronske mreže	3
2.1.1. Biološke neuronske mreže.....	3
2.1.2. Umjetne neuronske mreže	5
2.2. Definicija i osobitosti umjetne neuronske mreže	6
2.2.1. Pojam umjetne neuronske mreže.....	6
2.2.2. Umjetni neuron.....	6
2.2.3. Primjena neuronskih mreža	9
2.2.4. Faze stvaranja neuronske mreže.....	9
3. Stvaranje neuronske mreže.....	11
3.1. Modeli neuronskih mreža	11
3.2. Učenje umjetnih neuronskih mreža	14
3.3. Višeslojne neuronske mreže	18
4. Upotreba neuronske mreže za predviđanje BDP-a.....	21
4.1. Opis problema	21
4.2. Pregled prethodnih istraživanja	21
4.2.1. Predviđanje BDP-a Hrvatske.....	22
4.2.2. Predviđanje BDP-a korištenjem neuronskih mreža.....	24
4.3. Priprema podataka	29
4.3.1. Opis podataka	29
4.3.2. Priprema podataka za analizu.....	30
4.3.3. Opis atributa	31
4.4. Analiza podataka	33
4.5. Prikaz rezultata	36
4.6. Usporedba rezultata	43
5. Zaključak	45
Popis literature.....	46
Popis slika	48
Popis tablica	50

1. Uvod

Metode i tehnike umjetne inteligencije nude cijeli niz prednosti kod modeliranja sustava, organizacija i procesa. Nude mogućnost učenja iz podataka, neizrazitosti i dinamičnosti. Takve prednosti dolaze do izražaja izradom modela rudarenja podataka koji pomažu rješavanju konkretnih poslovnih problema u različitim područjima društvenih znanosti (Garača i Jadrić, 2011, str. 15-16). Primarni cilj umjetne neuronske mreže je povezati stečeno znanje na slične te nove i nepoznate ulaze pa se stoga tu govori o umjetnoj inteligenciji (Bilan, bez dat.).

Neuronske mreže su tek jedna od više metoda rudarenja podataka. Ona, kao i svaka druga metoda rudarenja podataka uključuje analizu koja dijeli populaciju na uzorak za učenje i uzorak za testiranje. Algoritam na uzorku za učenje pokušava na temelju podataka raspoznati pravilnosti, uzorke te vrijednosti koeficijenata postavljenog modela. Uzorak za testiranje se koristi kako bi se nakon treninga provjerila pouzdanost dobivenog rješenja (Panian i Klepac, 2003, str. 277).

Predviđanje ekonomskog rasta danas je najvažnija tema ekonomskih stručnjaka. Predviđanje daje važne podatke koji oblikuju gospodarstvo neke države. Povećanjem ekonomskog rasta se smatra povećanje proizvodnje u promatranjoj zemlji gdje se životni standard stanovnika te zemlje uvelike povećava. Predviđanjem se bavi sve više institucija i pojedinaca.

U praktičnom dijelu će se prikazati predviđanje ekonomskog rasta u Republici Hrvatskoj korištenjem umjetne neuronske mreže. Upotrebom alata JMP će se metodom umjetnih neuronskih mreža, na temelju podataka Hrvatskog zavoda za statistiku, analizirati kretanje BDP-a te utjecaj pojedinih varijabli na BDP. Dodatni je cilj uočiti kako promjene nekih varijabli utječu na kretanje drugih varijabli, zatim koje varijable u većoj, a koje u manjoj mjeri utječu na BDP.

2. Neuronske mreže

Neuronske mreže su vrlo snažan alat, a posebno ako je riječ o prognoziranju trendova i predviđanju na temelju povijesnih podataka. Uspješno se koriste i u robotici te kod alarmnih sustava za prepoznavanje uzoraka. Neuronska mreža se može na temelju povijesnih podataka istrenirati te tako postaje sposobna davati odgovore za slučajeve koji nisu obuhvaćeni povijesnim podacima. Treniranje neuronske mreže može biti dugotrajan proces koji zahtjeva strpljenje i spremnost na redizajn ako se model mreže ne pokaže efikasnim. Treniranje mreže omogućuje smanjivanje sveukupne pogreške, no kod nekih slučajeva, posebno kod kompleksnijih modela, je smanjivanje sveukupne pogreške vrlo sporo, gotovo pa neznajno. Praksa je da dokle god sveukupna pogreška pokazuje trend padanja, da se nastavi s treniranjem mreže jer je to dobar put postizanja cilja (Panian i Klepac, 2003, str. 326).

Budući da neuronske mreže karakterizira smanjena mogućnost interpretacije rezultata obrade, prilikom rudarenja podataka se metode neuronskih mreža kombiniraju s ostalim konceptima i metodama rudarenja podataka (npr. neizrazita logika) koje mogu biti od pomoći pri interpretaciji rezultata. Dodatne metode koje se pritom koriste služe upravo kvalitetnoj interpretaciji rezultata (Panian i Klepac, 2003, str. 327).

2.1. Razlika biološke i umjetne neuronske mreže

Pretpostavlja se da ljudski mozak ima oko 100 milijardi neurona te da je svaki od njih povezan s oko 1000 do 10000 drugih neurona. Nije do kraja razjašnjeno djelovanje bioloških neurona, ali se je pokazalo da jednostavni modeli umjetnih neurona mogu pomoći pri rješavanju mnogih zadataka u znanosti, tehnici i u drugim primjenama (Leksikografski zavod Miroslav Krleža, bez dat.).


Umjetne neuronske mreže su nastale po uzoru na biološke neuronske mreže, ali se ipak razlikuju po nekim karakteristikama. U nastavku slijedi više riječi o svakoj te o prepoznatljivim razlikama između njih.

2.1.1. Biološke neuronske mreže

Ljudski mozak je vrlo kompleksno, paralelno i nelinearno računalo. Neuroni su kod ljudskog mozga pet do šest redova veličine sporiji od digitalne logike, no mozak taj nedostatak brzine nadoknađuje velikim brojem neurona i međuspojeva (Lončarić, 2018).


Biološki neuron je stanica koja prima informacije od drugih neurona putem dendrita. Potom slijedi obrada informacija te slanje impulsa putem aksona i sinapsi drugim neuronima u mreži. Učenje se odvija mijenjanjem jačine sinaptičkih veza. U mreži se mogu nalaziti milijuni neurona te mogu istovremeno obrađivati informacije (Ivić, Jurković, Marinković, 2012).

Na slici 1 se nalazi prikaz tzv. piramidalnog neurona kod čovjeka. On može imati i više od 10 tisuća ulaznih sinapsi, a njegov izlaz se može prenositi na tisuće drugih neurona. Uloga dendrita je primanje ulaza s drugih neurona, axon prenosi dalje impulse, a sinaptički terminali dotiču dendrite drugih neurona (Lončarić, 2018).



Slika 1: Piramidalni neuron
(Izvor: Lončarić, 2018)

Prednosti bioloških neuronskih sustava su brzina kojom izvode proračune te otpornost prema negativnim (štetnim) utjecajima okoline te unutarnjim degradacijama signala. Neuronski sustav kod čovjeka ima tri glavna dijela (slika 2). Kao neuronska mreža se prikazuje mozak koji predstavlja centralni dio sustava. Uloga receptora je vršiti pretvorbu podražaja od vanjske okoline u električne impulse koji mrežom prenose informacije. Odziv sustava prema okolini predstavljaju efektori koji pretvaraju električne impulse neuronske mreže. Na slici strelice u desno predstavljaju prijenos informacija unaprijed kroz sustav, a strelice u lijevo predstavljaju povratnu vezu sustava (Bilan, bez dat.).



Slika 2: Neuronski sustav čovjeka
(Prema: Bilan, bez dat.)

2.1.2. Umjetne neuronske mreže

Za razliku od biološkog, umjetni neuron se definira kao varijabla, odnosno kao jedinica za obradu podataka. Ta jedinica prima od drugih varijabli ponderirane ulazne vrijednosti. Prema određenoj formuli varijabla vrši transformaciju primljene vrijednosti te šalje izlaz drugim varijablama. Promjenom vrijednosti težina među varijablama se odvija učenje (Ivić i ostali, 2012).

Model umjetnog neurona sastoji se od zbrajala na koji je vezan određeni broj ulaznih veza. Svaki pojedini ulaz sadrži ulazne vrijednosti koje se množe prije zbrajanja s težinskim faktorom. Rezultat zbrajanja je ulazna vrijednost odabrane prijenosne funkcije neurona. Rezultat prijenosne funkcije neurona predstavlja izlazne vrijednosti neurona. Izlazne vrijednosti neurona potom postaju ulaznim vrijednostima drugih, budući da su nakupine takvih neurona međusobno spojene te zajedno tvore neuronsku mrežu. Uobičajena je pravilna struktura neurona koju čini ulazni sloj neurona, izlazni sloj te jedan ili više skrivenih unutarnjih slojeva. U ulaznom sloju su ulazne vrijednosti neurona zapravo vrijednosti cijele mreže, dok su kod izlaznog sloja izlazne vrijednosti neurona zapravo izlazne vrijednosti mreže. Nakon odabira strukture mreže je potrebno prilagoditi težinske faktore pojedinih veza. To prilagođavanje se naziva učenjem mreže. Radi se o tome da se na ulazu mreže dovodi niz ulaznih vrijednosti za koje su već poznate izlazne vrijednosti te je još potrebno prilagoditi težinske faktore kako bi se izlazne vrijednosti mreže što više približile unaprijed poznatima. Nakon što se na poznatom uzorku provede učenje, mreža daje dobre rezultate i za druge ulazne vrijednosti (Leksikografski zavod Miroslav Krleža, bez dat.).

Umjetne neuronske mreže su slične mozgu po sljedećem:

- Znanje se stječe kroz proces učenja,
- Za spremanje znanja se koriste međusobne veze između neurona (Lončarić, 2018).

Kod umjetnih neuronskih mreža se računala nastoje približiti mogućnostima mozga i bioloških mreža tako da se imitiraju procesni elementi mozga na pojednostavljen način. Dok mozak ima sposobnost učenja, računalo je u tome dijelu vrlo malo zastupljeno, a tolerancija na pogreške, koja je prisutna kod mozga, u računalu nije zastupljena (Bilan, bez dat.).

2.2. Definicija i osobitosti umjetne neuronske mreže

Umjetna neuronska mreža je jedna od metoda rudarenja podataka. Cilj je pronaći veze među podacima. Jedinica za obradu podataka je umjetni neuron koji koristi određene funkcije. Više o tome slijedi u nastavku.

2.2.1. Pojam umjetne neuronske mreže

Prema definiciji za neuronske mreže, neuralno procesiranje podataka je proučavanje mreža prilagodljivih čvorova koje se kroz proces učenja iz spremljenih podataka mogu osposobiti za rješavanje problema iz područja iz kojeg potječu eksperimentalni realni podaci (Panian i Klepac, 2003, str. 314).

Prema Leksikografskom zavodu Miroslava Krležu, bez dat., navodi se da je „neuronska mreža, u računalstvu i informatici, sustav međusobno povezanih elemenata (nazvanih umjetni neuroni) koji služi za raznovrsna izračunavanja, zasnovan na pokušaju oponašanja rada ljudskog mozga“.

Umjetna neuronska mreža spada u inteligentne metode rudarenja podataka kojima je cilj pronaći skrivene veze među podacima. Neuronska mreža je nakupina jednostavnih elemenata obrade. Riječ je o čvorovima (jedinicama) čiji je rad temeljen na načinu djelovanja neurona živih bića. Neuronske mreže su programi ili hardverski sklopovi gdje se iteracijama iz prethodnih podataka nastoji pronaći veza između ulaznih i izlaznih varijabli, s ciljem da se za nove ulazne varijable dobije vrijednost izlaza (Zekić – Sušac, Frajman – Jakšić, Drvenkar, 2009).


2.2.2. Umjetni neuron

Jedinica za obradu podataka je umjetni neuron. On prima ponderirane ulazne vrijednosti od drugih varijabli, potom primjenjuje formulu pomoću koje transformira primljenu vrijednost te izlaz šalje drugim varijablama (Zekić – Sušac i ostali, 2009).

Svaka neuronska mreža se sastoji od više neurona. Prikaz neurona nalazi se na slici 3. Osnovna funkcija neurona je sljedeća:

- Prikupiti informacije od susjednih jedinica,

- Uskladiti unutarnje razine aktivacije,
- Proračunati te proslijediti izlaz daljnjim jedinicama (Vouk, Malus, Carević, 2010).




Slika 3: Neuron
(Vouk i ostali, 2010)

Model neurona se sastoji od tri glavna elementa:

- Skup ulaza (sinapsi) pri čemu svaki od njih ima svoju jačinu, odnosno težinu,
- Sumator za zbrajanje otežanih ulaza,
- Nelinearna aktivacijska funkcija koja ima zadaću ograničiti izlaz neurona na interval $[0, 1]$ (Lončarić, 2018).

Ideja o neuronskim mrežama potječe iz neuropsihologije odakle su iskorištena saznanja o ponašanju živčane stanice koja funkcionira po principu povećanja potencijala na sinapsama, odnosno po principu aktivacije. Saznanja o biološkom modelu neuronskih mreža su iskorištena za formiranje matematičkog modela koji se koristi u praksi. Osnovna jedinica u matematičkom modelu je dizajnirana po uzoru na biološki neuron. Jedinice kombiniraju ulaze u jedinstveni rezultat, obično je riječ o funkciji sumiranja, koji je zatim preusmjeren u funkciju transformacije, a ona kalkulira izlaznu vrijednost koja obično poprima vrijednost između 0 i 1 (Panian i Klepac, 2003, str. 315). Aktivacijsku funkciju neurona čine kombinacijska i transferna funkcija zajedno, a to je prikazano na slici 4.



Slika 4: Matematički model neurona
(Izvor: Panian i Klepac, 2003, str. 315)

Kombinacijska funkcija može biti funkcija sume, funkcija minimuma ili logičkih operatora vezanih težinskim koeficijentima. Najvažnija je, odnosno obično se koristi funkcija sume s težinskim koeficijentima (Panian i Klepac, 2003, str. 316).

Funkcija transformacije je druga funkcija, odnosno drugi dio aktivacijske funkcije. Ona je zadužena za transferiranje vrijednosti kombinacijske funkcije u izlazne jedinice kojom je aktivacija cijelog modela uvjetovana. Funkcije transformacije su obično sljedeće:

- Sigmoidna funkcija,
- Linearna funkcija,
- Hiperbolička tangencijalna funkcija (Panian i Klepac, 2003, str. 316).

Rijetko se koristi linearna funkcija, a ima i ograničenu primjenu. Njezinim se korištenjem u jedinicama neuralne mreže model mreže pretvara u alat za linearnu regresiju. Nelinearne funkcije su ostale dvije, sigmoidna i hiperbolička tangencijalna funkcija pa su stoga i rezultati njihove obrade također nelinearni. Razlika sigmoidne i hiperboličke tangencijalne funkcije je u tome da sigmoidna funkcija producira izlaze u intervalima između

-1 i 1, a hiperbolička tangencijalna u intervalu između 0 i 1. Sigmoidna funkcija je najčešće korištena (neki izvori literature ju nazivaju S – funkcija), a njezina formula je sljedeća:

$$S(x) = \frac{1}{1 + e^{-x}}$$

X je u prethodnoj formuli rezultat kombinacijske funkcije koja predstavlja sumarnu funkciju produkta težinskih koeficijenata (budući da svaki neuron ima svoj težinski koeficijent) i ulaznih parametara. Preporuka je da ulazni parametri budu izraženi u vrijednostima između 0 i 1. U programima se može kreirati procedura koja će vrijednosti konvertirati u zadane okvire (Panian i Klepac, 2003, str. 316).

Nad svakim se neuronom izvodi ograničeni broj jednostavnih operacija. Neuroni se obično organiziraju u slojeve radi jednostavnije i brže provedbe algoritamskih funkcija (Vouk i ostali, 2010).

2.2.3. Primjena neuronskih mreža

Vouk i ostali (2011) navode dva osnovna skupa problema gdje se neuronske mreže uspješno primjenjuju u njihovom rješavanju:

- Klasifikacijski problemi. Radi se o problematici kod koje je definirana kategorija kojoj pripada nepoznata veličina, a koja je unaprijed opisana skupom ulaznih podataka. U rješavanju klasifikacijskih problema su neuronske mreže izuzetno korisni alati, iako je riječ o problemima velike složenosti i težine gdje je ostale metode rudarenja podataka (npr. metoda stabla odlučivanja, metoda indukcije) teško ili čak nemoguće primijeniti.
- Numerički problemi. Radi se o situacijama gdje je u odnosu na skup ulaznih podataka potrebna procjena izlazne vrijednosti u numeričkom obliku. U praksi u gotovo svim područjima ljudske djelatnosti se javljaju numerički problemi. Primjena neuronskih mreža je obično vezana za analizu velikih numeričkih baza podataka.

2.2.4. Faze stvaranja neuronske mreže

Ivić i ostali (2012) navode tri faze stvaranja neuronske mreže:

1. Faza učenja (treniranja),
2. Faza unakrsne validacije,
3. Faza testiranja.

Prije prve faze je potrebno definirati ulazne i izlazne varijable, odnosno definirati model te prikupiti podatke na kojima će se primijeniti mreža. Potom je podatke potrebno podijeliti na tri uzorka, odnosno za fazu treniranja, unakrsnu validaciju te testiranje. Preporuka je da se najveći dio podataka primjeni na treniranje mreže, a ostali manji dio na testiranje i validaciju (u postocima je to 70% na treniranje, a po 15% za testiranje i validaciju). Prvi korak pri stvaranju neuronske mreže je faza učenja ili treniranja mreže. Riječ je o procesu gdje se mijenjaju težine u mreži, a to predstavlja odgovor na podatke izvana koji su predstavljeni ulaznom sloju, a u nekim mrežama i izlaznom sloju. Izlaznom sloju su predstavljeni podaci koji su željene vrijednosti izlaznih varijabli. Faza učenja se provodi kako bi mreža prepoznala vezu između podataka te da bude u mogućnosti na osnovi ulaznih vrijednosti predvidjeti izlaze. Više o samoj fazi učenja u poglavlju 3. U idućoj fazi, odnosno fazi unakrsne validacije, mreža nastoji optimizirati duljinu treniranja, parametre i broj skrivenih neurona. U trećoj fazi se provodi testiranje mreže i ona je odlučujuća za ocjenjivanje mreže. Razlika između faze testiranja i faze učenja je u tome što u fazi testiranja mreža više ne uči. Ocjenjivanje mreže predstavlja izračunavanje greške ili drugog mjerila točnosti (kao što je stopa točnosti) tako da se izlaz mreže uspoređuje sa stvarnim izlazima.

3. Stvaranje neuronske mreže

Nakon identifikacije problema se utvrđuje može li se navedeni problem riješiti uz pomoć neke od metoda neuronskih mreža, odnosno donosi se odluka o rješavanju problema. Ako se problem može riješiti primjenom neke od metoda neuronskih mreža, tada se izabire odgovarajući model. Nakon toga se odabire broj skrivenih slojeva i ulazno izlaznih neurona. Po završetku se određuju parametri učenja (težinski koeficijenti). Etapa inicijalizacije mreže počinje izborom skupa podataka za treniranje. Ta etapa predstavlja predetapu treniranja (učenja) mreže. Po završetku koraka se istrenirana mreža podvrgava testiranju. Mreža se primjenjuje u praksi tek ako su rezultati zadovoljavajući, a ako nisu onda se je potrebno vratiti na neki od prethodnih koraka te je potrebno ponavljanje procesa. Ponekad je dovoljno promijeniti neadekvatne težinske koeficijente ili broj skrivenih slojeva neurona, a vrlo rijetko u praksi se javlja potreba za mijenjanjem modela same mreže (Panian i Klepac, 2003, str. 318).


Često se spominje i perceptron, prvi model neuronske mreže koji je razvijen uz pomoć računala. Riječ je o najjednostavnijem obliku nepovratne (jednosmjerne) neuronske mreže. Sastoji se od dva sloja neurona, ulaznog i izlaznog (Vouk i ostali, 2010).

3.1. Modeli neuronskih mreža

Ne postoji univerzalni model neuronske mreže primjenjiv na sve vrste problema. Do sada razvijeni modeli imaju određene prednosti kod primjene u nekom određenom području. Modeli neuronskih mreža se primjenjuju u numeričkim analizama ekonomskih aplikacija koje prognoziraju određene vrijednosti nekih pojava, za planiranje, za klasifikaciju pojava u skupine i drugo. Panian i Klepac, 2003, str. 317-320, navode nekoliko modela neuronskih mreža:

- Jedan od prvih primjenjivanih modela u praksi je bio McCulloch - Pittov model gdje se princip učenja temelji na delta pravilu te se obično primjenjuje kod prepoznavanja uzoraka. Dizajner mreže pri tome, radi njegove prepoznatljivosti, modelira matematičku prezentaciju modela. Nedostatak je u nemogućnosti uočavanja parnosti, povezanosti i simetrije poznato kao *Hard Learning problem*, a upravo je to značajna prepreka u rješavanju određenih tipova problema. Bilan (bez dat.) navodi da se ovdje radi o funkciji praga te da je svojstvo takvog modela sve ili ništa.

- Hopfieldov model je utemeljen na autoasocijativnosti i primjenjiv je u praksi. Ima mogućnost rješavanja numeričkih problema i ima visok stupanj promjenjivosti. Nedostatak su mu lokalni minimum i maksimum, ali to uspješno rješava nadogradnjom Boltzmannovog načela iz područja fizike.
- Sljedeći model su Kohonenove samoorganizirajuće mape, koje su zasnovane na učenju koji se obično primjenjuje u području poslovne inteligencije.
- Model unazadne propagacije (širenja) pogrešaka, odnosno algoritam „širenje unatrag“ (eng. *Backpropagation*). Riječ je o najpoznatijem i najčešće upotrebljavanom modelu. On koristi funkciju radijalne baze. Karakterizira ga značajna razlika u fiksnim vrijednostima težinskih koeficijenata u skrivenom sloju neurona. Ovaj model se najčešće koristi u svrhu prognoziranja određenih vrijednosti nekih pojava, za planiranje itd., a upravo su to glavna područja primjene neuronskih mreža. Model podrazumijeva neograničen broj slojeva skrivenih neurona, a njihov broj ovisi o odluci dizajnera mreže. Riječ je o mreži s punom strukturom međuveza, što znači da su sve vrijednosti neurona međusobno povezane i ovisne te utječe na krajnji rezultat treninga mreže. Struktura ovog modela je prikazana na slici 5.



Slika 5: Model neuronske mreže s unazadnom propagacijom (širenjem) pogrešaka


(Izvor: Ivić i ostali, 2012)

Svaki neuron iz ulaznog sloja je spojen sa svim neuronima skrivenog sloja, a svaki neuron skrivenog sloja je spojen sa svim neuronima izlaznog sloja. Veze među neuronima su isključivo jednosmjerne te se kreću od ulaznog prema skrivenom do izlaznog sloja.

Skriveni sloj neurona se tumači kao mjesto koje skladišti međurezultate nakon proračuna, a radi krajnje obrade. Međurezultati se koriste pri generiranju izlaznih vrijednosti neurona izlaznog sloja. Nema nikakvog pravila da bi se odredio broj skrivenih slojeva neurona. On isključivo ovisi o problemu koji se nastoji riješiti, a u praksi se određuje metodom pokušaja i pogrešaka.

Ovaj algoritam je zaslužan za široku komercijalnu upotrebu ove metodologije. Uz to je neuronske mreže učinio široko upotrebljavanom i popularnom metodom za razna područja primjene. Glavni nedostatak je problem čestog pronalaženja lokalnog minimuma greške umjesto globalnog minimuma greške (Zekić – Sušac i ostali, 2009).

Neuronska mreža od samo jednog neurona, odnosno perceptron, je najjednostavnija neuronska mreža (slika 6). Perceptron se formira nelinearnim neuronom koji predstavlja model neurona McCulloch – Pitts. Rosenblatt (kao što citira Bilan) navodi da za izlaz perceptrona umjetni neuron za aktivacijsku funkciju ima funkciju praga. Pri tome je aktivacijska funkcija \emptyset perceptrona funkcija praga, odnosno Heaviside step funkcija. Na slici 6 oznake $X_1, X_2, X_3, \dots, X_m$ predstavljaju vanjske signale za podražaj. Perceptron mora klasificirati njihov skup u jednu od dvije izlazne klase C1 ili C2, odnosno istinu ili laž. Ako je izlaz perceptrona y jednak 1, tada se točka X_i pridružuje C1 klasi, a ako je izlaz perceptrona y jednak 0, tada se točka X_i pridružuje C2 klasi. Perceptron može izračunati gotovo sve binarne Booleove logičke funkcije što pokazuje njegovu veliku logičku sposobnost, iz čega proizlazi da perceptron sa samo dva ulaza može izračunati 14 do 16 mogućih funkcija (Bilan, bez dat.).



Slika 6: Perceptron
(Izvor: Bilan, bez dat.)

3.2. Učenje umjetnih neuronskih mreža

Jedno od najvažnijih karakteristika neuronske mreže je sposobnost učenja (treniranja) od okoline. Učenje o okolini neuronska mreža vrši kroz iterativni proces podešavanja sinaptičkih težina i pragova, a nakon svake iteracije učenja bi mreža trebala imati više saznanja o okolini. Ne postoji jedinstveni algoritam učenja (skup pravila za rješavanje problema učenja), već mnogo različitih algoritama i to svaki sa svojim prednostima i nedostacima. Prilikom učenja se implicira ovakav slijed događaja:

- Okolina stimulira neuronsku mrežu,
- Rezultat stimulacije je mijenjanje neuronske mreže,
- Neuronska mreža zbog nastalih promjena drugačije reagira na okolinu (Lončarić, 2018).

Neuralna mreža učenjem pamti određene zakonitosti unutar skupa raspoloživih podataka (scenarija). Ulazna baza podataka mora imati za veliki broj scenarija definirane zavisne varijable na temelju čijih vrijednosti će neuronska mreža pamtili određene zakonitosti te donositi odluke za novodefinirane scenarije. Proces učenja je relativno spor i zahtjevan

proces, a odnosi se na optimizaciju težinskih faktora u vezama između neurona (Vouk i ostali, 2010).

Proces treniranja neuronske mreže ima nekoliko koraka:

- Generiranje inicijalnih vrijednosti,
- Računanje vrijednosti neurona (faza unaprijed),
- Računanje odstupanja,
- Korekcija parametara na temelju izračunate pogreške (Zekić – Sušac i ostali, 2009).

U procesu treniranja vrijednosti pogreške također trebaju težiti prema 0, a ako to nije tako tada se trebaju mijenjati polazne pretpostavke, kao što je selekcija samog modela, broj skrivenih slojeva te inicijalne vrijednosti težinskih koeficijenata (Zekić – Sušac i ostali, 2009).

Dvije su paradigme učenja, autoasocijativno (uzorci se pridružuju sebi samima – klasteriranje) i heteroasocijativno učenje (dva različita tipa uzoraka se pridružuju jedan drugom), pri čemu su temeljni princip učenja neuronskih mreža veze između eksperimentalnih uzoraka. Postupci učenja se mogu podijeliti u tri skupine, neovisno o tome koriste li procedure učenja vanjske signale (povratnu vezu okoline) ili ne:

- Nadzirano učenje,
- Nenadzirano učenje,
- Pridružujuće pojačavajuće učenje.

Kod nadziranog učenja, tzv. učenje s učiteljem, metodom povratne veze se uklanjaju razlike između željenog izlaza i stvarnog izlaza uzoraka. Kod nenadziranog učenja, naglasak je na samoorganizaciji, odnosno klasteriranju, pa se ne pojavljuje povratna veza za razliku od ostala dva modela. Treća skupina učenja, pridružujuće pojačavajuće učenje, tzv. učenje s kritikom, se temelji na povratnoj vezi koja indicira kada se aktualni i željeni uzorci podudaraju, a uz to je i evaluacijski orijentirano (Panian i Klepac, 2003, str. 317). Glavna razlika između nadziranog i nenadziranog učenja je ta da su kod nadziranog tipa učenja poznate vrijednosti izlaznih varijabli na skupu podataka za učenje, dok kod nenadziranog tipa učenja one nisu poznate (Ivić i ostali, 2012).

Samoorganizirajuće mreže uče bez nadzora, odnosno ne postoji učitelj koji bi bio uključen u proces učenja. Kod takvih mreža ne postoje informacije o tome koju bi vrijednost izlazi trebali imati za pojedine ulaze. Zadatak mreže je da samostalno otkrije uzorke, kategorije ili korelacije u ulaznim podacima. Ovisno o arhitekturi mreže, postoji više uzoraka koju mreža otkriva u ulaznim podacima. Isto tako postoji više različitih arhitektura

samoorganizirajućih mreža koje imaju različite namjene. Ovakav tip učenja je koristan kod aplikacija kada nije raspoloživa informacija o željenom izlazu, a primjenjuje se i kod grupiranja za analizu podataka, klasifikaciju objekata ili uzoraka, preslikavanje značajki i drugo (Lončarić, 2018).

Lončarić (2018) dijeli metode učenja prema algoritmu učenja na sljedeće:

- Učenje korekcijom pogreške. Riječ je o primjeru učenja pod nadzorom. Učenje korekcijom pogreške ima cilj minimizirati funkciju pogreške temeljenu na pogreškama tako da se dobiveni odziv svih neurona približava željenom, u nekom statističkom smislu. Kao funkcija pogreške se najčešće koristi srednja kvadratna pogreška:

$$J = E \left[\frac{1}{2} \sum_k e_k^2(n) \right]$$

pri čemu je $E[\cdot]$ statistički operator očekivanja, a sumacija se vrši za sve neurone u izlaznom sloju mreže.


- Kompetitivno učenje. Riječ je o učenju bez nadzora. Ovdje se neuroni natječu za priliku kako bi se aktivirali, ali samo jedan neuron ili jedan po grupi može biti aktivan u bilo kojem trenutku. Ograničena je jačina svakog neurona te skup jednakih neurona sa slučajno raspoređenim težinama različito reagira na dani skup ulaza.
- Boltzmannovo učenje. Riječ je o stohastičkom algoritmu temeljenom na teoriji informacija i termodinamici. Koristi se kod Boltzmannovog stroja koji se sastoji od stohastičkih neurona, a koji mogu poprimiti jedno od dva stanja (-1 ili +1). Postoje povratne veze, a neuroni su međusobno povezani.
- Thorndikeovo učenje. Radi se o principu učenja podrškom kod kojeg ne postoji učitelj koji će određivati kolika je pogreška za određeni par ulaza – izlaza, već je uloga učitelja da kaže koliko je određeni korak dobar u učenju, odnosno učitelj daje ocjenu ili podršku. Vjerojatnost da će sustav poduzimati iste akcije u budućnosti je veći ako akcije za učenje izazivaju pozitivni efekt i obrnuto.

Kod procesa učenja se koristi generalizirano delta pravilo koje spada u kategoriju nadgledanog učenja. Učenje se odvija u dvije faze. Faza unaprijed računa uzorak izlaznih vrijednosti koji se kasnije uspoređuju sa željenim rezultatima. Druga faza je faza unatrag u kojoj se dobiveni rezultati uspoređuju sa željenima, potom se izračunava pogreška te se vrši

korekcija parametara izlaznog i skrivenog sloja u svrhu ispravljanja pogreške. Na osnovi cijelog modela mreže se teži postići što je moguća manja sveukupna pogreška (eng. *Overall Error*), čime se jamči uspješnost modela (Zekić – Sušac i ostali, 2009).

Na osnovu vrijednosti varijable sveukupne pogreške, odnosno indikatora uspješnosti učenja, se u procesu učenja mreže odlučuje treba li prekinuti ili nastaviti proces učenja. Sveukupna pogreška je ukupna vrijednost svih razlika između željenog izlaza i stvarnog izlaza uzoraka i trebala bi težiti prema 0. Sveukupna pogreška je indikator uspješnosti učenja u modelu propagacije (širenja) pogrešaka u neuralnoj mreži (Panian i Klepac, 2003, str. 317).


Učenje je automatizirani proces koji je definiran prethodnim odabirom algoritma učenja. U praksi se najčešće koristi algoritam učenja s povratnom propagacijom pogreške, a to je ujedno temeljni algoritam učenja nadziranih neuralnih mreža. Spomenuti algoritam je sadržan u velikom dijelu komercijalnih oblika neuronskih mreža. U ulaznom sloju se odabire niz slučajnih početnih težina u vezama neurona te se za izlaz dobije vrijednost koju mreža potom uspoređuje s vrijednosti željenog izlaza, odnosno s uzorkom izlazne vrijednosti putem koje mreža uči. Ako dođe do odstupanja dobivene vrijednosti od očekivane, tada se težine u vezama automatski prilagođavaju s ciljem da se smanji odstupanje izlazne vrijednosti od očekivane. Kada se ostvari neznatna veličina odstupanja, tada se proces učenja prekida, a mreža je spremna za testiranje s novim uzorcima (Vouk i ostali, 2010). Prethodno opisani postupak učenja je prikazan na slici 7.



Slika 7: Postupak učenja neuronske mreže
(Izvor: Vouk i ostali, 2010)

3.3. Višeslojne neuronske mreže

Razlikujemo jednoslojne i višeslojne neuronske mreže. Jednoslojne mreže se sastoje od jednog sloja neurona, tj. samo od izlaznog sloja. One sadrže i ulazni sloj, no on se ne broji jer u njemu nema procesiranja. Ulazi u mrežu su spojeni na ulaze neurona te njihovi izlazi su ujedno i izlazi mreže (Lončarić, 2018). Slika 8 prikazuje jednoslojnu neuronsku mrežu.




Slika 8: Jednoslojna neuronska mreža

(Izvor: autorski rad)

Za razliku od jednoslojnih mreža, višeslojne mreže imaju uz ulazni i izlazni sloj jedan ili više skrivenih slojeva neurona. Kada je riječ o povezanosti mreže, ona može biti:

- Potpuno povezana – svaki je neuron u svakom sloju povezan na sve neurone u sljedećem sloju
- Djelomično povezana – neka veza nedostaje (Lončarić, 2018).

Slika 9 prikazuje primjer višeslojne neuronske mreže s jednim skrivenim slojem u kojem ima četiri neurona. Ukupno je četiri ulazna neurona, s time da njihov broj može biti različit od broja skrivenih neurona. Izlaznih neurona ima dva.



Slika 9: Višeslojna neuronska mreža

(Izvor: Lončarić, 2018)

4. Upotreba neuronske mreže za predviđanje BDP-a

Predviđanje ekonomskog rasta je danas vrlo važan makroekonomski pokazatelj, a njime se bavi veliki broj ekonomskih stručnjaka, institucija i pojedinaca.

Promatranjem ekonomskog rasta u Republici Hrvatskoj dolazimo do velikih oscilacija. Od 2009. godine ekonomski rast u Republici Hrvatskoj bio je u negativnom trendu. Na negativnu stopu godišnjeg rasta prethodio je financijski slom američkog tržišta koji je zbog ekonomske povezanosti utjecao na europsku ekonomiju, uzrokujući recesiju, čak i u najvećim europskim državama. Tek 2015. godine dolazi do oporavka ekonomskog rasta u Hrvatskoj. Do nagle promjene dolazi zbog snažnog rasta izvoza za što je najzaslužniji rast gospodarstva Europske unije kao najvećeg hrvatskog vanjsko trgovinskog partnera (Sičić, 2016).

Stručnjaci Državnog zavoda za statistiku predviđaju najbrži rast Hrvatskog BDP-a u zadnjih 10 godina i to zbog dvije važne promjene. Zbog rasta plaća i zaposlenosti koje potiču veću osobnu potrošnju. U 2017. je usporen rast industrijske proizvodnje ali je znatno povećan rast u turizmu (Dnevnik.hr, 2017).

4.1. Opis problema

Problem koji se rješava u ovom radu je predviđanje ekonomskog rasta u Republici Hrvatskoj. Predvidjeti ekonomski rast nije trivijalan zadatak jer mnogo čimbenika ovisi o njemu. Za predviđanje će se koristiti javno dostupni podaci Državnog zavoda za statistiku.

Čimbenici koji će se gledati prilikom istraživanja su sljedeći:

- Odnos uvoza i izvoza,
- Potrošnja,
- Investicije.

4.2. Pregled prethodnih istraživanja

Informacije o različitim predviđanjima BDP-a Republike Hrvatske često se mogu pronaći u domaćim medijima. Takva istraživanja provode različite organizacije i agencije. U nastavku će biti prikazano nekoliko takvih istraživanja što će omogućiti usporedbu rezultata predviđanja s rezultatima ostalih institucija. Predviđanja koja će biti prikazana iznijeli su Svjetska banka, Ekonomski institut u Zagrebu te Europska komisija.

4.2.1. Predviđanje BDP-a Hrvatske

Svjetska banka procijenila je krajem 2017. godine da će BDP u 2018. godini rasti za 2.6, a u 2019. za 2.8 posto. „Očekuje se da će osobna potrošnja ostati robusna, odražavajući fiskalno ublažavanje, oporavak tržišta rada i povećanje povjerenja potrošača“ navodi Svjetska banka, a prenosi Tportal, 2017. Izvoz roba ocjenjuju ključnim u poticanju rasta, a inozemna potražnja glavnih trgovinskih partnera jača. Ističu i da će se zahvaljujući sredstvima iz EU fondova intenzivirati ulaganja, a posebice javne investicije u infrastrukturu. Predviđa se i smanjenje deficita, a time i udjela javnog duga u BDP-u. Stopa nezaposlenosti trebala bi 2019. pasti ispod 10 posto. Rizici za gospodarstvo su umjereni, kako ističe Svjetska banka. Rizike predstavljaju visoka razina zaduženosti privatnog sektora, problemi u Agrokoru te da Hrvatska treba idućih godina refinancirati znatan dio javnog duga (Tportal, 2017).

Ekonomski institut (2017) izradio je predviđanje BDP-a za kraj 2017. godine i za 2018. godinu. Istraživanje je provedeno pomoću pokazatelja BDP-a i njegovih čimbenika iz 5. rujna 2017. Predviđanje je nešto optimističnije od onoga Svjetske banke. Naime, predviđa se da će BDP u 2018. godini porasti za 3.3 posto. Svi rezultati predviđanja za 2018. godinu prikazani su na slici 10. Podaci prikazuju predviđenu postotnu promjenu u odnosu na raniju godinu. Vidljivo je da se predviđaju promjene u svim čimbenicima koji utječu na BDP. Svi čimbenici promijenit će se u korist povećanja BDP-a ako gledamo njihov utjecaj na hrvatski BDP i gospodarstvo.

	2017	2018
BDP (% promjene)	3.1	3.3
Stvarna osobna potrošnja (% promjene)	4.1	3.1
Stvarna potrošnja države (% promjene)	1.6	1.3
Stvarne investicije (% promjene)	5.1	5.7
Izvoz roba i usluga (stvarne cijene, % promjene)	8.2	5.7
Uvoz roba i usluga (stvarne cijene, % promjene)	10.4	6.9
Račun bilance plaćanja (% BDP-a)	4.0	2.8
Saldo države (ESA 2010, % BDP-a)	-0.4	0.5
Javni dug (ESA 2010, % BDP-a)	82.2	80.0
Stopa nezaposlenosti (registriranih, %, pa)	12.8	11.9
Tečaj, HRK / EUR (pa)	7.46	7.45
Ukupni plasman banaka (% promjene, eop)	0.3	3.4
Potrošačke cijene (% promjene, pa)	1.1	1.5
*pa – prosječno razdoblje		
**eop – na kraju razdoblja		

Slika 10: Predviđanja BDP-a za 2018. godinu

(Izvor: Ekonomski institut, 2017)

Što se tiče predviđanja Europske komisije (2017) BDP bi u 2018. godini trebao porasti za 2.8 posto, a u 2019. za 2.7 posto u odnosu na prethodnu godinu. Na slici 11 se mogu vidjeti i predviđanja za promjene postotnih vrijednosti kod čimbenika koji utječu na BDP. Europska komisija naglašava da će gospodarska aktivnost malo izgubiti zamah i da će se BDP 2019. tek vratiti na stanje prije gospodarske krize. Potencijalni negativni utjecaj predstavlja restrukturiranje Agrokora. Stopa nezaposlenosti će nastaviti padati, ali problem predstavljaju imigracije. Možemo zaključiti da je predviđanje Europske komisije vrlo slično onom Svjetske banke. Razlika u postotku rasta BDP-a za 2018. i 2019. godinu iznosi samo 0.2, odnosno 0.1 posto.

Objašnjenje oznaka a), b), c) i d) sa slike 11:

- a) % ukupne radne snage,
- b) Bruto štednja podijeljena s prilagođenim bruto raspoloživim prihodom,
- c) % BDP – a,
- d) % potencijalnog BDP – a.

Kategorije za predviđanje BDP-a Hrvatske									
	2016		98-13	Godišnja postotna promjena					
	Trenutna cijena	% BDP		2014	2015	2016	2017	2018	2019
BDP	345.2	100.0	1.6	-0.5	2.2	3.0	3.2	2.8	2.7
Osobna potrošnja	199.9	57.9	1.2	-1.6	1.1	3.3	3.6	2.8	2.3
Javna potrošnja	66.3	19.2	1.4	-0.8	-1.4	1.3	1.7	1.7	1.0
Bruto investicije u fiksni kapital	69.3	20.1	2.1	-2.8	3.8	5.1	4.2	5.0	6.6
od kojih: oprema	-	-	-	-	-	-	-	-	-
Izvoz roba i usluga	171.4	49.7	3.7	6.0	9.4	5.7	6.2	5.8	5.0
Uvoz roba i usluga	160.9	46.6	2.3	3.1	9.2	5.8	6.9	6.3	5.8
GNI (BDP deflator)		96.5	1.5	-0.5	3.7	0.0	4.4	1.4	2.6
Doprinos rastu BDP-a:	Domaća potražnja:		1.6	-1.7	1.1	3.2	3.3	3.0	2.9
	Zalihe		-0.2	-0.1	0.8	-0.3	0.0	0.0	0.0
	Neto izvoz		0.3	1.3	0.3	0.1	-0.1	-0.1	-0.2
Zaposlenost			0.4	2.7	1.2	0.3	1.8	1.7	1.5
Stopa nezaposlenosti (a)			-	17.2	16.1	13.4	11.1	9.2	7.5
Naknade radnika po glavi			4.4	-5.4	-0.2	-0.1	2.5	2.5	2.5
Jedinični troškovi rada cijelog gospodarstva			3.1	-2.4	-1.2	-2.8	1.1	1.3	1.3
Stvarna jedinična cijena rada			-0.4	-2.4	-1.2	-2.7	0.0	-0.7	-0.8
Ušteda stope kućanstva (b)			-	-	-	-	-	-	-
BDP deflator			3.5	0.0	0.0	-0.1	1.2	2.1	2.1
Usklađeni indeks potrošačkih cijena			-	0.2	-0.3	-0.6	1.3	1.5	1.6
Uvjeti trgovačke robe			1.0	-0.9	-1.2	-0.6	-1.4	0.4	0.4
Trgovinska bilanca (roba) (c)			-18.4	-15.1	-15.8	-16.0	-17.4	-18.0	-18.5
Stanje na tekućem računu (c)			-	2.0	4.6	2.3	3.1	1.9	1.9
Neto pozajmljivanje (+) ili zaduživanje (-) u odnosu na (c)			-	2.2	5.3	3.3	3.8	2.7	2.7
Državna bilanca (c)			-	-5.1	-3.3	-0.9	-0.9	-0.9	-0.7
Ciklično prilagođena bilanca (d)			-	-2.9	-1.8	-0.2	-1.1	-1.9	-2.0
Strukturni proračunski saldo (d)			-	-3.1	-1.8	-0.3	-0.9	-1.9	-2.0
Bruto dug države (c)			-	85.8	85.4	82.9	80.3	77.4	74.5

Slika 11: Predviđanje BDP-a Hrvatske od strane Europske komisije

(Izvor: Europska komisija, 2017)

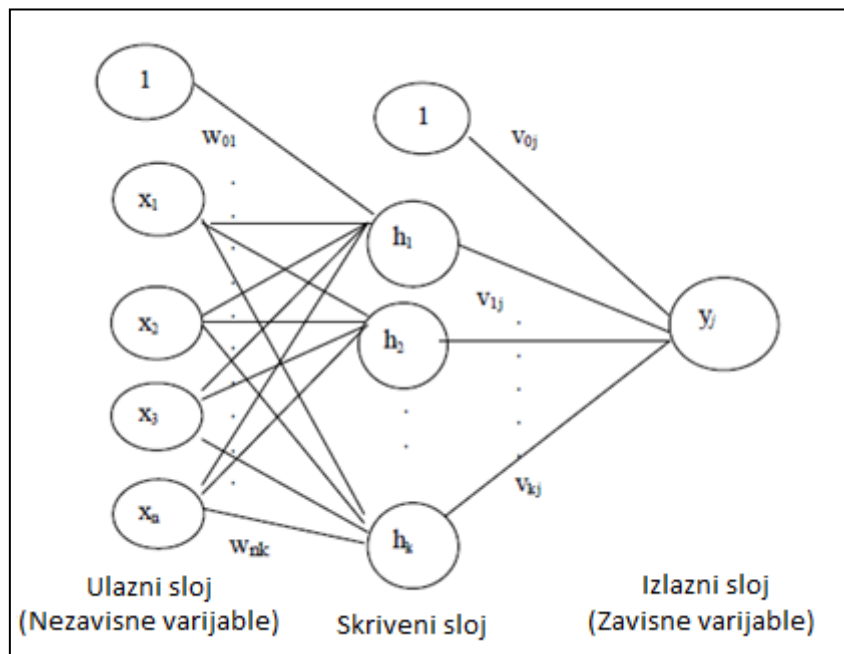
4.2.2. Predviđanje BDP-a korištenjem neuronskih mreža

Teško je pronaći istraživanja vezana uz predviđanje ekonomskog rasta pomoću neuronskih mreža za Republiku Hrvatsku, no u svijetu su provedena brojna takva istraživanja. Prikazana će biti istraživanja vezana uz predviđanje BDP-a Malezije i predviđanje ekonomskog rasta Benina primjenom neuronskih mreža.

2004. godine u Maleziji je napravljena usporedba u predviđanju BDP-a koristeći neuronske mreže i ekonometrijski pristup koji koristi standardne statističke kriterije mjerenja. Kod predviđanja pomoću neuronskih mreža korištene su četiri nezavisne varijable:

- Broj korisnika mobitela na tisuću stanovnika,
- Broj korisnika interneta na tisuću stanovnika,
- Broj računala na tisuću stanovnika,
- Broj instalacija osobnih računala na tisuću stanovnika (Kolej Universiti Kejuruteraan Utara Malaysia, 2004).

Na slici 12 je prikazan model neuronskih mreža koji je korišten za predviđanje BDP-a Malezije, gdje oznaka x predstavlja nezavisnu varijablu, h predstavlja sloj skrivenih čvorova, dok y predstavlja izlazni čvor.



Slika 12: Model neuronskih mreža

(Izvor: Kolej Universiti Kejuruteraan Utara Malaysia, 2004)


Rezultati istraživanja pokazali su da je predviđanje koristeći neuronske mreže pokazalo korektnije rezultate od predviđanja ekonometrijskim pristupom. Usporedba rezultata dobivenih navedenim metodama (srednja kvadratna greška, srednja apsolutna greška i postotak korektnosti) prikazana je na slici 13.

	Model neuronskih mreža	Ekonometrijski model
Srednja kvadratna greška	0.578	3.504
Srednja apsolutna greška	0.334	3.068
Postotak korektnosti	83.33	62.47

Slika 13: Usporedba rezultata dobivenih dvjema metodama

(Izvor: Kolej Universiti Kejuruteraan Utara Malaysia, 2004)

Korištenje modela neuronskih mreža pokazalo se boljom metodom za predviđanje BDP-a. To predviđanje u konačnici je pokazalo rezultate jednake stvarnim rezultatima, osim za 1998. godinu kada je recesija pogodila globalnu ekonomiju (slika 14).



Slika 14: Usporedba rezultata predviđanja malezijskog BDP-a korištenjem neuronskih mreža sa stvarnim vrijednostima BDP-a

(Izvor: Kolej Universiti Kejuruteraan Utara Malaysia, 2004)

Na kineskom Sveučilištu elektroničke znanosti i tehnologije (International Journal of Engineering Research & Technology [IJERT], 2014) provedeno je istraživanje koristeći neuronske mreže kojim se predviđa ekonomski rast za državu Benin (Afrika). Bazirajući se na stvarnim ekonomskim podacima izvučene su ekonomske klasifikacije koje uključuju diskretizaciju atributa, rang važnosti atributa, redukciju atributa i pravilo predviđanja. Tada se podaci unose u neuronsku mrežu u obliku učenja podataka.


Korišteni su podaci iz 2014. godine koji su dobiveni iz izvještaja beninskog ministarstva financija i Nacionalnog instituta za statistiku i ekonomiju. Varijable koje su korištene prikazane su na slici 15.

X_i	Varijable ($1 \cdot 10^9$ CFA. [$\$1 \approx 478$ CFA])
X_1	Poljoprivreda
X_2	Uzgoj, životinje
X_3	Ribolov, šumarstvo
X_4	Industrija
X_5	Tvornice
X_6	Energija
X_7	BTP
X_8	Trgovina
X_9	Prijevoz i telekomunikacije
X_{10}	Banka, osiguranje
X_{11}	Druge usluge
X_{12}	Ne komercijalne usluge
X_{13}	PISB
X_{14}	DTI i VAT
X_{15}	Uvoz
X_{16}	Izvoz
Y	BDP (izlaz)

Slika 15: Varijable za predviđanje ekonomskog rasta Benina

(Izvor: IJERT, 2014)

Na slici 16 prikazana je regresijska usporedba između stvarnih podataka i predviđanja izražena u Matlab softveru. Može se vidjeti da se krivulje na grafu većinom podudaraju što bi značilo da su predviđanja jako dobro napravljena.



Slika 16: Regresijska usporedba između stvarnih podataka i predviđanja
(Izvor: IJERT, 2014)

U tablici 1 prikazani su rezultati usporedbe rezultata predviđanja BDP-a poslije simulacije i stvarnih podataka za Benin (Afrika). Vidljivo je da su rezultati vrlo slični pa se može zaključiti da se model temeljen na neuronskim mrežama može vrlo efikasno koristiti kod ekonomskih predviđanja.

Tablica 1: Usporedba između predviđenog BDP-a i stvarnog BDP-a - Benin

Godina	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000
Simulirana vrijednost	596,4	608,4	629,0	667,5	912,1	1091,6	1230,5	1343,1	1453,0	1544,1	1692,0
Stvarna vrijednost	533,6	560,4	594,4	644,1	887,3	1083,0	1207,8	1323,9	1448,4	1532,4	1679,6
Godina	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	
Simulirana vrijednost	1859,6	1965,1	2056,5	2133,0	2309,4	2468,0	2646,0	2961,3	3090,8	3216,0	
Stvarna vrijednost	1832,1	1956,9	2067,5	2140,0	2298,7	2460,2	2639,0	2970,5	3109,1	3247,9	

(Izvor: IJERT, 2014)

Na temelju podataka do 2007. godine napravljeno je predviđanje za sljedećih pet godina. Ti rezultati prikazani su u tablici 2.

Tablica 2: Predviđanja ekonomskog rasta Benina za razdoblje 2008. – 2012.

Godina predviđanja	Predviđena vrijednost
Y+1 (2008)	2.8557e+003
Y+2 (2009)	2.9905 e+003
Y+3 (2010)	3.1531 e+003
Y+4 (2011)	3.6685 e+003
Y+5 (2012)	4.1895 e+003

(Izvor: IJERT, 2014)

Iz predviđanja ekonomskog rasta Malezije, odnosno Benina možemo zaključiti kako je model neuronskih mreža vrlo precizan i učinkovit kod ekonomskih predviđanja.

4.3. Priprema podataka

Podaci za istraživanje su prikupljeni s web stranice Državnog zavoda za statistiku. Podaci koji su preuzeti se odnose na godišnji bruto domaći proizvod prema osnovnim kategorijama izdataka i područjima djelatnosti za godine od 2000. do 2016. (Državni zavod za statistiku, 2017).

4.3.1. Opis podataka

Državni zavod za statistiku (2017) je kod izrade podataka primijenio sljedeće klasifikacije: klasifikaciju osobne potrošnje prema namjeni (COICOP), Standardnu međunarodnu trgovinsku klasifikaciju (SMTK) te Glavnu klasifikaciju proizvoda (CPC) za BDP u tekućim cijenama i u stalnim cijenama po kategorijama izdataka.

Procjena BDP-a uključuje sve djelatnosti unutar granica proizvodnje definirane ESA-om 2010 i obuhvaća cjelokupno područje Republike Hrvatske. Metodologija koja je korištena u ovom radu je rashodna metoda tekućih cijena. Obračun BDP-a u tržišnim cijenama prema rashodovnoj metodi u tekućim cijenama se temelji na podacima iz redovitih istraživanja

Državnog zavoda za statistiku, Ministarstva financija, Hrvatske narodne banke i Financijske agencije (Državni zavod za statistiku, 2017).

Za obračun izdataka za potrošnju kućanstava upotrijebljeni su podaci iz redovitih istraživanja Državnog zavoda za statistiku o prometu u trgovini na malo te o prometu u hotelima i restoranima. Za obračun izdataka za finalnu potrošnju države te izdataka za finalnu potrošnju neprofitnih ustanova koje služe kućanstvima (NPUSK) su se koristila tromjesečna statistička istraživanja o prihodima i rashodima proračuna i proračunskih korisnika i neprofitnih organizacija te podaci Ministarstva financija za opću državu (Državni zavod za statistiku, 2017).


Bruto investicije u fiksni kapital su obračunate s pomoću metode robnih tokova upotrebom podataka o proizvodnji i uvozu kapitalne opreme te podataka o graditeljstvu. Promjena zaliha je obračunata na temelju podataka iz tromjesečnog istraživanja o rezultatima poslovanja poduzetnika do četvrtog tromjesečja 2012. nakon čega su korišteni podaci Državnog zavoda za statistiku o zalihama (Državni zavod za statistiku, 2017).

Podaci o uvozu i izvozu dobara i usluga se temelje na bilanci plaćanja Hrvatske narodne banke. Podaci o uvozu i izvozu robe obuhvaćaju samo robu kod koje dolazi do promjene vlasništva između rezidenta i nerezidenta (Državni zavod za statistiku, 2017).

4.3.2. Priprema podataka za analizu

Državni zavod za statistiku u preuzetom Excelu nudi nekoliko načina prikaza bruto domaćeg proizvoda. Prva mogućnost koju nude je prikaz podataka na godišnjoj razini ili za tromjesečja. U ovom radu su podaci uzeti po tromjesečju. Zatim nude prikaz prema tekućim cijenama, stalnim cijenama prethodne godine, stalnim cijenama referentne godine (2010.=100) te prema realnim stopama rasta. U ovom radu je uzet prikaz obračuna bruto domaćeg proizvoda prema rashodnoj metodi prema tekućim cijenama.

Slika 17 prikazuje zaglavlje izvorne tablice Državnog zavoda za statistiku koja se koristi u radu za potrebe istraživanja.

A1 12.1.1.1.													
A	B	C	D	E	F	G	H	I	J	K	L		
1	12.1.1.1.												
2	TROMJESEČNI OBRAČUN BRUTO DOMAĆEG PROIZVODA PREMA RASHODNOJ METODI, tekuće cijene¹⁾												
3	QUARTERLY GROSS DOMESTIC PRODUCT, BY EXPENDITURE APPROACH, current prices¹⁾												
4	Molimo korisnike da pri korištenju podataka navedu izvor.												
5	Users are kindly requested to state the source.												
6													
7													
8	 DRŽAVNI ZAVOD ZA STATISTIKU REPUBLIKE HRVATSKE CROATIAN BUREAU OF STATISTICS							Stvarna individualna potrošnja	Bruto investicije				
9									Gross capital formation				
10	Ukupno			Država									
11	Households and NPISH			General government									
12	Ukupno			kućanstva	NPUSK	Ukupno	individualna	kolektivna	Actual individual consumption	Ukupno	bruto investicije u fiksni kapital	promjena zaliha	
13	Total			Households	NPISH	Total	Individual	Collective		Total	Gross fixed capital formation	Changes in inventories	
14	1=2+5			2=3+4	3	4	5=6+7	6	7	8=2+6	9=10+11	10	11
33	2000.												
34	I. – III.	35.413	25.944	25.332	612	9.470	4.675	4.794	30.619	9.180	7.486	1.694	
35	IV. – VI.	37.416	27.831	27.187	643	9.585	4.734	4.851	32.565	10.287	9.834	453	
36	VII. – IX.	35.897	26.249	25.595	654	9.648	4.768	4.879	31.018	5.293	9.666	-4.374	
37	X. – XII.	40.686	30.935	30.261	674	9.752	4.825	4.927	35.760	11.560	8.966	2.594	
38	2001.												
39	I. – III.	38.150	28.729	28.188	541	9.421	4.692	4.730	33.421	11.855	8.869	2.986	
40	IV. – VI.	40.813	31.383	30.842	541	9.430	4.697	4.733	36.080	14.528	10.830	3.697	

Slika 17: Prikaz izvorne tablice s dijelom zaglavlja i podataka
(Izvor: autorski rad)

4.3.3. Opis atributa

U nastavku se nalazi tablica s popisom atributa koji su odabrani za istraživanje (tablica 3). Napomena: značenje kratice NPUSK – neprofitne ustanove koje služe kućanstvima.


Tablica 3: Popis i opis atributa

Naziv atributa	Opis atributa	Tip podatka
Razdoblje	Prikaz BDP-a prema tromjesečjima od 2000. do trećeg tromjesečja 2017.	Tekstualni
Kućanstva i NPUSK	Zbroj potrošnje kućanstava i neprofitnih ustanova koje služe kućanstvima	Brojčani
Potrošnja države	Potrošnja države je zbroj individualne i kolektivne potrošnje	Brojčani
Stvarna individualna potrošnja	Zbroj potrošnje kućanstva i NPUSK te individualne potrošnje države	Brojčani
Bruto investicije u fiksni kapital	Obračunate su pomoću metode robnih tokova korištenjem podataka o graditeljstvu te o proizvodnji i uvozu kapitalne opreme	Brojčani
Promjena zaliha	Obračunata je na osnovi podataka iz tromjesečnog istraživanja o rezultatima poslovanja poduzetnika (do 4.tromjesečja 2012); nakon toga je obračunata iz podataka Državnog zavoda za statistiku o zalihama	Brojčani
Izvoz roba	Podaci se temelje na bilanci plaćanja Hrvatske narodne banke. Podaci obuhvaćaju robu kod koje dolazi do promjene vlasništva između rezidenta i nerezidenta.	Brojčani
Izvoz usluga	Podaci se temelje na bilanci plaćanja Hrvatske narodne banke.	Brojčani
Uvoz roba	Podaci se temelje na bilanci plaćanja Hrvatske narodne banke. Podaci obuhvaćaju robu kod koje dolazi do promjene vlasništva između rezidenta i nerezidenta.	Brojčani
Uvoz usluga	Podaci se temelje na bilanci plaćanja Hrvatske narodne banke.	Brojčani
Bruto domaći proizvod	Zbroj konačne potrošnje, bruto investicija ukupnog izvoza roba i usluga, umanjeno za uvoz roba i usluga	Brojčani

(Izvor: autorski rad)

4.4. Analiza podataka

Nakon pripreme podataka, iste je bilo potrebno učitati u alat za analizu i obradu podataka gdje je potom korištena metoda za modeliranje neuronskih mreža. Korišten je alat JMP verzije 13.2.1 preuzet sa službene stranice (JMP, 2018). U nastavku se nalazi slika s opisom alata (slika 18).




Slika 18: Alat JMP verzije 13.2.1

(Izvor: autorski rad)

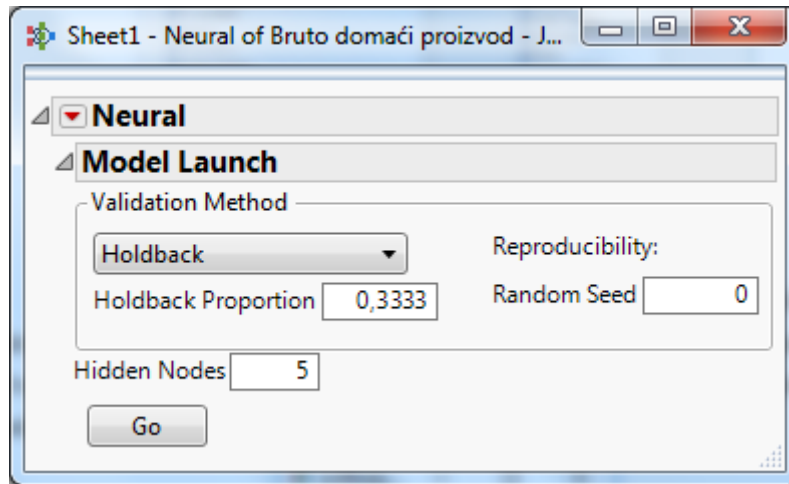
Slike 19 i 20 prikazuju grafičko sučelje alata te prikaz učitanih podataka iz Excela. Osim zaglavlja, učitano je 87 redova zapisa za podatke od 2000. do 2017. godine te ukupno 11 stupaca (jedan stupac koji prikazuje razdoblja za koja su uzeti podaci + 10 stupaca podataka).

Idući je korak definiranje zavisnih i nezavisnih varijabli što je prikazano na slici ispod (slika 21). Zavisna varijabla (Y) je Bruto domaći proizvod, a sve ostale su nezavisne (osim varijable Razdoblje koja nije uključena niti u jednu skupinu).



Slika 21: Definiranje zavisnih i nezavisnih varijabli
(Izvor: autorski rad)

U *Control Panelu* je najvažniji parametar broj skrivenih čvorova (eng. *Hidden Nodes*). Ako se postavi premala vrijednost, može doći do pojave gdje mreža nije dovoljno kompleksna s obzirom na raspoložive komplicirane podatke (eng. *underfit*). Ako se postavi prevelika vrijednost, može doći do pojave pretreniranosti (eng. *overfitting*) podataka (mreža je prekompleksna za određene podatke te je osjetljiva na smetnje). U ovom istraživanju je broj skrivenih čvorova postavljen na 5 (polovica broja varijabli), a ostali parametri nisu mijenjani (slika 22).



Slika 22: Podešavanje opcija neuronske mreže
(Izvor: autorski rad)

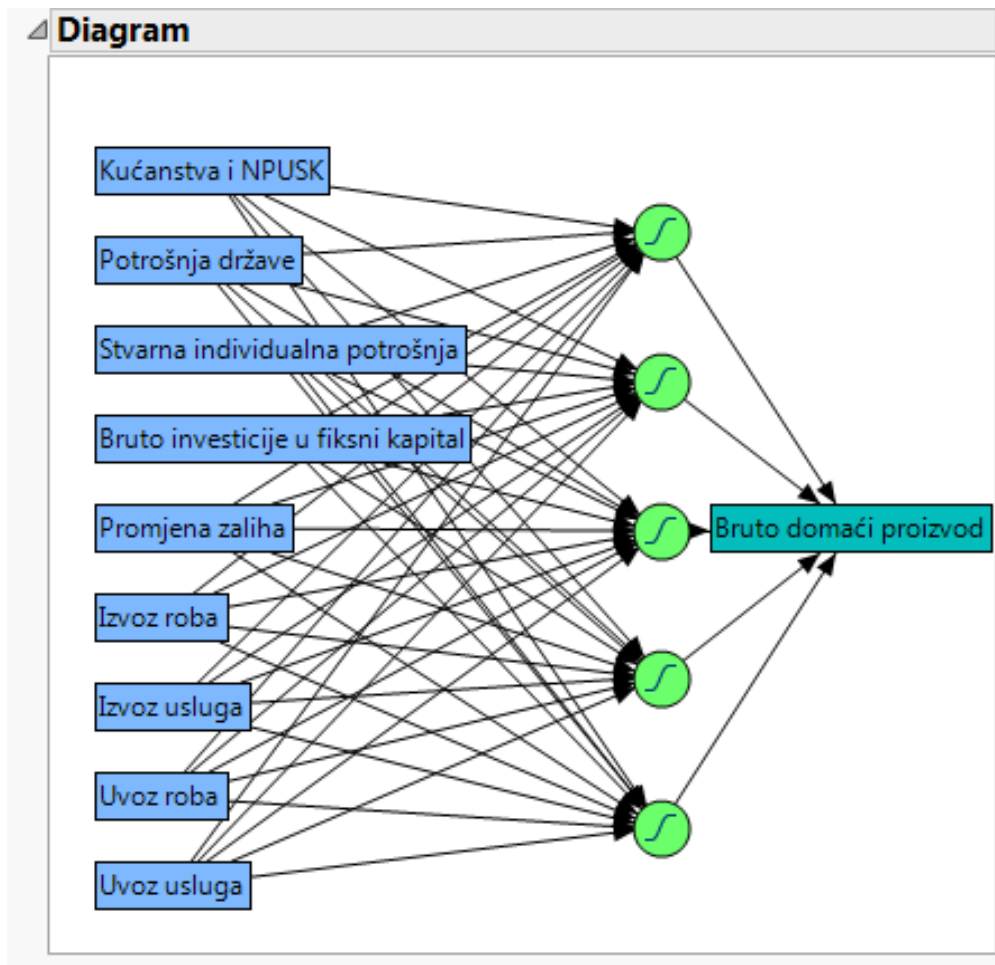
4.5. Prikaz rezultata

Sljedeća slika (slika 23) prikazuje rezultate treninga i validacije, odnosno provjere valjanosti. Što je *RSquare* parametar veći (bliže 1), to je pouzdanost bolja, što znači da je i model bolji. Uočavamo da je pouzdanost kod treninga i kod validacije gotovo 1 što je jako dobro. Parametar *RMSE* označava grešku, a model je bolji što je greška manja. U ovom istraživanju je kod treninga *RMSE* bliže nuli, dok je kod validacije ta vrijednost dosta veća.

Training		Validation	
Measures	Value	Measures	Value
RSquare	0,9999991	RSquare	0,9999419
RMSE	13,705587	RMSE	113,00109
Mean Abs Dev	10,774428	Mean Abs Dev	57,956663
-LogLikelihood	234,13104	-LogLikelihood	178,24374
SSE	10894,901	SSE	370308,14
Sum Freq	58	Sum Freq	29


Slika 23: Rezultati treninga i validacije
(Izvor: autorski rad)

Elementi obrade kod neuronske mreže su smješteni u slojeve: jedan ulazni sloj, jedan ili više međuslojeva i jedan izlazni sloj. Slika 24 prikazuje dijagram na kojemu se jasno vidi ulazni sloj, skriveni sloj (pet međuslojeva) te izlazni sloj.



Slika 24: Dijagram neuronske mreže
(Izvor: autorski rad)

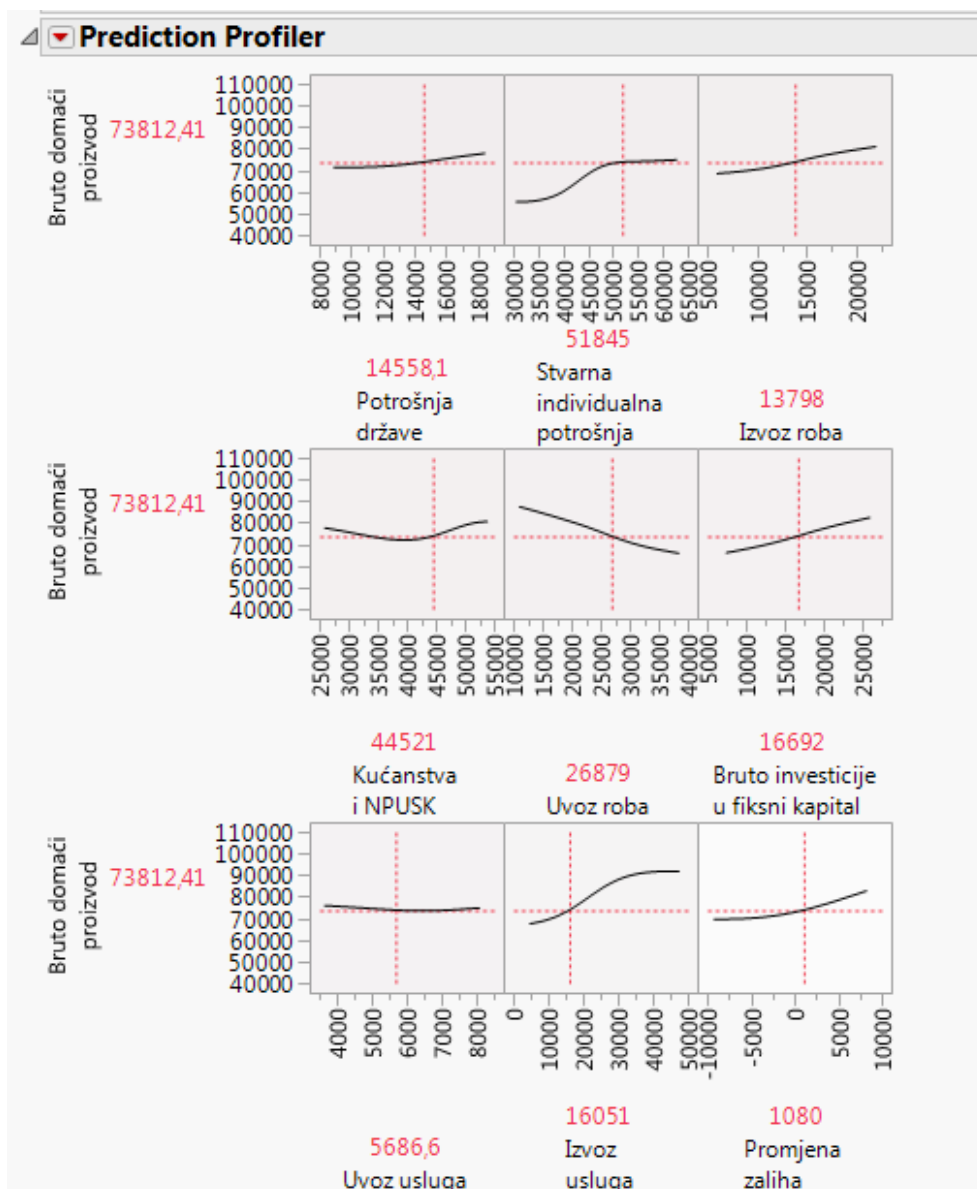
Slika 25 prikazuje varijable poredane po važnosti odnosno njihovom utjecaju. Vidimo da je prvih nekoliko varijabli gotovo jednako važno, odnosno imaju jednak utjecaj na BDP, dok je varijabla *Promjena zaliha* na kraju liste i ta varijabla u najmanjoj mjeri utječe na BDP. Najveći utjecaj na BDP imaju varijable *Potrošnja države*, *Stvarna individualna potrošnja* te *Izvoz roba*. U nastavku slike se nalazi grafički prikaz utjecaja svake varijable na BDP, dok su podaci označeni krivuljama. Redoslijed prikazanih grafikona prati poredak varijabli po važnosti, što bi značilo da se prvi dijagram odnosi na varijablu *Potrošnja države*, a posljednji dijagram na *Promjenu zaliha*.



Slika 25: Prikaz važnosti varijabli

(Izvor: autorski rad)

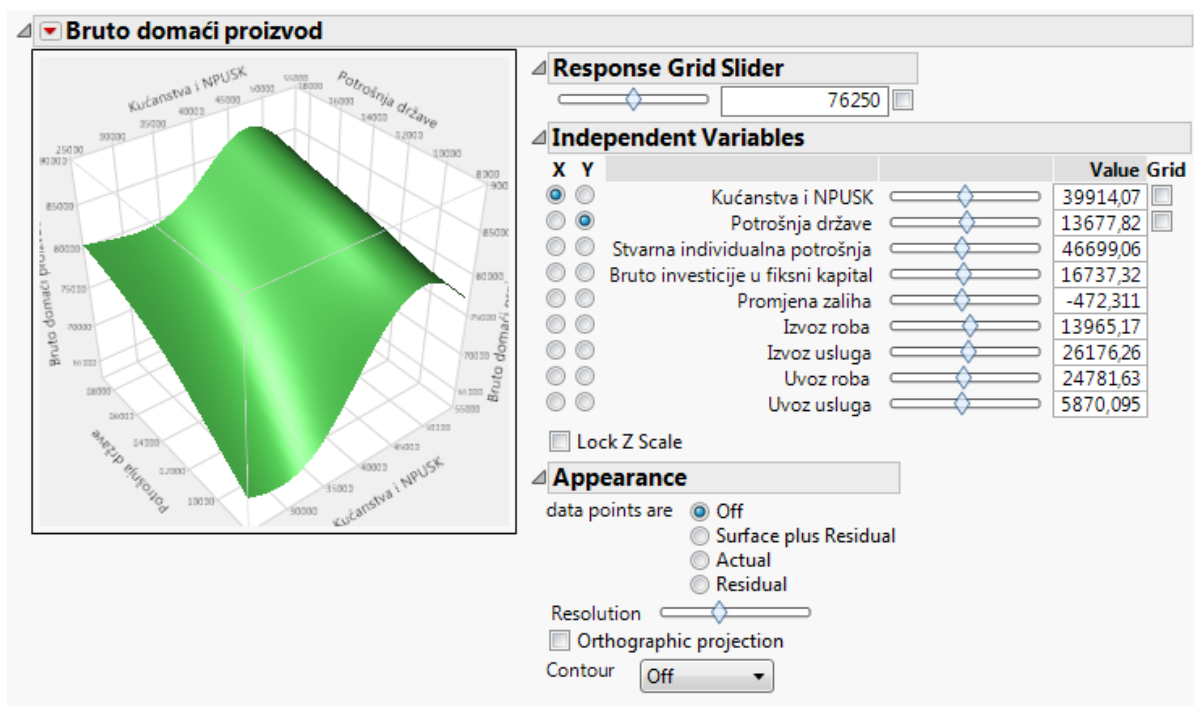
Iduće je prikaz opcije *Prediction Profiler* (slika 26) gdje se vidi kako pojedina varijabla utječe na BDP. Rezultat je prikazan kroz tri retka radi lakše analize, a po zadanom je u alatu postavljeno na jedan redak. Alat omogućuje mijenjanje vrijednosti parametara tako da se povlači crvena isprekidana linija lijevo i desno pri čemu se mijenjaju položaji svih dijagrama (pomiču se gore ili dolje) te se mijenja vrijednost bruto domaćeg proizvoda. Najmanju ovisnost uočavamo kod varijable *Uvoz usluga*. Promjenom tih varijabli se najmanje utječe na vrijednost bruto domaćeg proizvoda. Najveću ovisnost imaju varijable *Uvoz roba*, *Izvoz usluga* te *Stvarna individualna potrošnja*, što znači da se njihovim mijenjanjem najviše utječe na vrijednost bruto domaćeg proizvoda.



Slika 26: Prikaz varijabli u *Prediction Profiler*


(Izvor: autorski rad)

Opcija u alatu *Surface Profiler* (slika 27) je slična opciji *Prediction Profiler*, odnosno imaju istu svrhu, prikazati utjecaj pojedine varijable na BDP, odnosno međusobni odnos varijabli. Pregled je u obliku 3D modela što je dodatna prednost u odnosu na prethodni prikaz. U ovom primjeru slike, ona prikazuje utjecaj varijable *Kućanstva i NPUSK* (X os) te varijable *Potrošnja države* (Y os) na BDP. Vrijednost Bruto domaćeg proizvoda je iskazana na Z osi. Utjecaj ostalih varijabli na prethodne dvije varijable se oslikava pomicanjem znaka ♦ po liniji (događa se promjena vrijednosti varijable za koju se pomiče oznaka ♦).




Slika 27: Prikaz varijabli u prikazu *Surface Profiler*
(Izvor: autorski rad)

Slika 28 prikazuje stvarna predviđanja u obliku dijagrama. To omogućuje okvir *Actual by Predicted Plot*. Vidimo prikaz stvarne i predviđene vrijednosti za bruto domaći proizvod. Klikom na pojedinu točku se selektira pripadajući red u tablici u prozoru gdje se nalazi prikaz uvezenih podataka. Kod trening dijagrama točka koja je najviše pomaknuta u desno se odnosi na osamdeset i drugi zapis u tablici, odnosno na treće tromjesečje 2016. godine. Točka koja se nalazi najviše lijevo prema ishodištu, se odnosi na treći zapis u tablici. Zaključak je da nisu svi zapisi prikazani na ovome grafu, već samo dio njih.



Slika 28: Prikaz stvarnih predviđanja
(Izvor: autorski rad)

Idući dijagrami prikazuju pogreške predviđanja (slika 29). Pogreške su prikazane na Y osi, a na X osi se nalaze predviđanja. Taj prikaz je omogućen unutar okvira *Residual by Predicted Plot*. Klikom na određenu točku selektira se pripadajući red u tablici. Kod dijagrama treninga najudaljenija točka u ravni vrijednosti -40 se odnosi na sedmi zapis u tablici. Iz grafa se može pročitati da je vjerojatnost pogreške najmanja za točke blizu nula. Alat omogućuje označavanje pojedinih točaka bojom, što bi značilo da ako se neka od točaka oboji, da se oboji i zapis u tablici te se oboji i prikaz toga zapisa na ostalim dijagramima.



Slika 29: Prikaz pogreške predviđanja
(Izvor: autorski rad)

4.6. Usporedba rezultata

Nakon provedenog istraživanja i analize rezultata, uočava se kako na ekonomski rast utječu mnoge karakteristike. Karakteristike koje najviše utječu na vrijednost bruto domaćeg proizvoda su varijable *Potrošnja države*, *Stvarna individualna potrošnja* te *Izvoz roba*.

Kod istraživanja Svjetske banke, Ekonomskog instituta u Zagrebu te Europske komisije rezultati procjene prikazuju rast BDP-a. Njihova procjena istraživanja prikazuje da će BDP u 2018. i 2019. godini rasti. Procjene Svjetske banke i Europske komisije daju slične vrijednosti rasta BDP-a, dok istraživanje Ekonomskog instituta daje podatak da će BDP najviše rasti. Prema tim istraživanjima očekuje se pozitivan pomak varijabli koje utječu na BDP u modelu koji je kreiran u ovom radu pa se može zaključiti da će BDP rasti u sljedećem razdoblju. Koliko će iznositi rast ovisi o stopama promjena ulaznih varijabli.

Koliko predviđanja mogu biti različita i varljiva prikazuje rezultat sa stranice Trading Economics, bez dat. Naime, njihovo istraživanje predviđa da će BDP u Hrvatskoj padati što se vidi na grafu na slici 30.



Slika 30: Prikaz predviđanja BDP-a za 2018. godinu
(Izvor: Trading Economics, bez dat.)

Možemo zaključiti da različita istraživanja daju različite rezultate ovisno o provedenom istraživanju. Najveću razliku između podataka koji su korišteni u ovom radu te podataka koje su koristile Svjetska banka, Europska komisija i Ekonomski institut predstavljaju rizici. Navedene institucije, između ostalog, uzimaju i gospodarske rizike kao parametre procjene što u ovom radu nije bio slučaj.

5. Zaključak

Neuronske mreže se najčešće primjenjuju pri procjeni kreditnog rizika, u direktnom marketingu te u predviđanju prodaje. Nastanak umjetnih neuronskih mreža potječe od strane istraživača koji su željeli imitirati neuropsihologiju ljudskog mozga. Istraživači su se nadali da će proizvesti vrlo kompleksan fenomen poput inteligencije tako da kombiniraju mnogo jednostavnih elemenata za računanje neurona u jedan veliki i međusobno povezani sustav. Velika je rasprava o tome jesu li neuronske mreže zaista inteligentne, no nema sumnje oko toga da su postale vrlo značajan statistički alat (Garača i Jadrić, 2011, str. 62).

Cilj ovog rada bio je primijeniti neuronsku mrežu za predviđanje ekonomskog rasta. Procjena BDP-a je vrlo kompleksno područje. U obzir je potrebno uzeti puno različitih varijabli, no i to ne daje garanciju da će se BDP moći točno predvidjeti.

Kao jedan od najvećih problema prikazalo se prikupljanje podataka. Naime, premda je BDP pojam o kojemu se često govori o svakodnevnoj okolini, teško je naći kvalitetne i konkretne podatke. Često se podaci prikazuju na različite načine pa su stoga i predviđanja različita.

Nakon prikupljanja podataka i provedbe istraživanja dobivene su karakteristike prema kojima se kreirala neuronska mreža. Karakteristike koje su odabrane za analizu su: *Kućanstva i NPUSK, Uvoz roba, Izvoz roba, Uvoz usluga, Potrošnja države* te ostale. Moglo se primijetiti da najveću promjenu na rast BDP-a ima karakteristika *Potrošnja države* i *Stvarna individualna potrošnja*. Time se dovodi do zaključka da bi država imala rast BDP-a, potrebno je povećati kupovnu moć građana, budući da je potrošnja glavni faktor u promjeni rasta ili pada BDP-a. Varijabla *Promjena zaliha* ima najmanji utjecaj na BDP.

Upotreba neuronskih mreža ima izrazito široko područje primjene, gotovo u svim segmentima ljudskog djelovanja. Unutar područja makroekonomije, kao što je BDP, primjena neuronskih mreža u velikoj mjeri ubrzava i pojednostavljuje proces provođenja raznih analiza, a rezultira donošenjem kvalitetnih rezultata i zaključaka.

Popis literature

- Bilan, O. (bez dat.). *Uvod u obradu zvučnih signala umjetnim neuralnim mrežama*. Preuzeto 07.05.2018. s http://www.audiologs.com/ozrenbilan/05_DSP.pdf
- Dnevnik.hr (2017). *Makroekonomisti očekuju najbrži rast hrvatskog BDP-a u zadnjih 10 godina, i to zbog dvije važne promjene*. Preuzeto 10.03.2018. s <https://dnevnik.hr/vijesti/hrvatska/makroekonomisti-ocekuju-najbrzi-rast-hrvatskog-bdp-a-u-zadnjih-10-godina-i-to-zbog-dvije-vazne-promjene---497519.html>
- Državni zavod za statistiku (2017). *Bruto domaći proizvod*. Preuzeto 11.04.2018. s https://www.dzs.hr/Hrv_Eng/Pokazatelji/MSI%20BRUTO%20DOMACI%20PROIZVOD.xls
- Ekonomski institut (2017). *Croatian Economic Outlook*. Preuzeto 15.03.2018. s <http://www.eizg.hr/hr-HR/Croatian-Economic-Outlook-25.aspx>
- Europska komisija (2017). *CROATIA - Growth proves resilient but risks persist*. Preuzeto 11.03.2018. s https://ec.europa.eu/info/sites/info/files/economy-finance/ecfin_forecast_autumn_091117_hr_en.pdf
- Garača, Ž., Jadrić, M. (2011). *Rudarenje podataka: Različiti aspekti informacijskog društva*. Split: Ekonomski fakultet u Splitu
- International Journal of Engineering Research & Technology [IJERT]. (2014). *Africa economic growth forecasting research based on artificial neural network model: case study of Benin*. Preuzeto 16.04.2018. s http://www.academia.edu/9827337/Africa_Economic_Growth_Forecasting_Research_Based_on_Artificial_Neural_Network_Model_Case_Study_of_Benin
- Ivić, K., Jurković, Z., Marinković, R. (2012). Izrada modela neuronskih mreža za učestalost korištenja fakultetske knjižnice. *Ekonomski vjesnik : Review of Contemporary Entrepreneurship, Business, and Economic Issues*, XXV(1), 106-116. Preuzeto 19.05.2018. s <https://hrcak.srce.hr/84751>
- JMP (2018). *Data Analysis Software JMP* (Verzija 13.2.1). Preuzeto s https://www.jmp.com/en_us/download-jmp-free-trial.html
- Kolej Universiti Kejuruteraan Utara Malaysia (2004). *Predicting GDP growth in Malaysia using knowledge-based economy indicators: a comparison between neural network and econometric approaches*. Preuzeto 12.4.2018. s

<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.120.4658&rep=rep1&type=pdf>

Leksikografski zavod Miroslav Krleža (bez dat.). *Neuronska mreža*. Preuzeto 30.04.2018. s <http://www.enciklopedija.hr/natuknica.aspx?ID=43562>

Lončarić, S. (2018). *Neuronske mreže*. Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva. Preuzeto 20.03.2018. s https://www.fer.unizg.hr/predmet/neumre_a/predavanja

Panian, Ž., Klepac, G. (2003). *Poslovna inteligencija*. Zagreb: Masmedia d.o.o.

Sičić, J. (2016). *Investicije i gospodarski rast Republike Hrvatske* (Diplomski rad, Sveučilište u Splitu, Ekonomski fakultet). Preuzeto 12.03.2018. s <https://repositorij.efst.unist.hr/islandora/object/efst:145/preview>

TeX (2014). *Drawing back propagation neural network*. Preuzeto 14.05.2018. s <https://tex.stackexchange.com/questions/162326/drawing-back-propagation-neural-network>

Tportal (2017). *Svjetska banka povećala procjene rasta hrvatskog BDP-a*. Preuzeto 19.04.2018. s <https://www.tportal.hr/biznis/clanak/svjetska-banka-povecala-procjene-rasta-hrvatskog-bdp-a-foto-20171022>

Trading Economics (bez dat.). *Croatia GDP – Forecast*. Preuzeto 29.04.2018. s <https://tradingeconomics.com/croatia/gdp/forecast>

Vouk, D., Malus, D., Carević, D. (2011). Neuralne mreže i njihova primjena u vodnom gospodarstvu. *Građevinar*, 63(06.), 547-554. Preuzeto 11.05.2018. s <https://hrcak.srce.hr/70618>

Zekić-Sušac, M., Frajman-Jakšić, A., Drvenkar, N. (2009). Neuronske mreže i stabla odlučivanja za predviđanje uspješnosti studiranja. *Ekonomski vjesnik : Review of Contemporary Entrepreneurship, Business, and Economic Issues*, XXII(2), 314-327. Preuzeto 13.05.2018. s <https://hrcak.srce.hr/47931>

Popis slika

Slika 1: Piramidalni neuron.....	4
Slika 2: Neuronski sustav čovjeka	5
Slika 3: Neuron.....	7
Slika 4: Matematički model neurona	8
Slika 5: Model neuronske mreže s unazadnom propagacijom (širenjem) pogrešaka	12
Slika 6: Perceptron	14
Slika 7: Postupak učenja neuronske mreže	18
Slika 8: Jednoslojna neuronska mreža	19
Slika 9: Višeslojna neuronska mreža	20
Slika 10: Predviđanja BDP-a za 2018. godinu	23
Slika 11: Predviđanje BDP-a Hrvatske od strane Europske komisije.....	24
Slika 12: Model neuronskih mreža.....	25
Slika 13: Usporedba rezultata dobivenih dvjema metodama	25
Slika 14: Usporedba rezultata predviđanja malezijskog BDP-a korištenjem neuronskih mreža sa stvarnim vrijednostima BDP-a.....	26
Slika 15: Varijable za predviđanje ekonomskog rasta Benina	27
Slika 16: Regresijska usporedba između stvarnih podataka i predviđanja	28
Slika 17: Prikaz izvorne tablice s dijelom zaglavlja i podataka	31
Slika 18: Alat JMP verzije 13.2.1	33
Slika 19: Prikaz učitanih podataka iz Excela u alatu JMP (1/2)	34
Slika 20: Prikaz učitanih podataka iz Excela u alatu JMP (2/2)	34
Slika 21: Definiranje zavisnih i nezavisnih varijabli	35
Slika 22: Podešavanje opcija neuronske mreže.....	36
Slika 23: Rezultati treninga i validacije	37
Slika 24: Dijagram neuronske mreže	38

Slika 25: Prikaz važnosti varijabli.....	39
Slika 26: Prikaz varijabli u <i>Prediction Profiler</i>	40
Slika 27: Prikaz varijabli u prikazu <i>Surface Profiler</i>	41
Slika 28: Prikaz stvarnih predviđanja.....	42
Slika 29: Prikaz pogreške predviđanja	43
Slika 30: Prikaz predviđanja BDP-a za 2018. godinu	44

Popis tablica

Tablica 1: Usporedba između predviđenog BDP-a i stvarnog BDP-a - Benin	28
Tablica 2: Predviđanja ekonomskog rasta Benina za razdoblje 2008. – 2012.	29
Tablica 3: Popis i opis atributa	32