



UNIVERZITET U NIŠU  
ELEKTRONSKI FAKULTET



**Miroslav B. Milovanović**

**UPRAVLJANJE DINAMIČKIM SISTEMIMA  
PRIMENOM ADAPTIVNIH ORTOGONALNIH  
NEURONSKIH MREŽA**

DOKTORSKA DISERTACIJA

Niš, 2017.



UNIVERZITET U NIŠU  
ELEKTRONSKI FAKULTET



**Miroslav B. Milovanović**

**UPRAVLJANJE DINAMIČKIM SISTEMIMA  
PRIMENOM ADAPTIVNIH ORTOGONALNIH  
NEURONSKIH MREŽA**

DOKTORSKA DISERTACIJA

Niš, 2017.



UNIVERSITY OF NIŠ  
FACULTY OF ELECTRONIC  
ENGINEERING



**Miroslav B. Milovanović**

**CONTROL OF DYNAMICAL SYSTEMS BY  
USING ADAPTIVE ORTHOGONAL NEURAL  
NETWORKS**

PhD dissertation

Niš, 2017.

## Podaci o disertaciji

<b>I Autor</b>	
Ime i prezime	Miroslav B. Milovanović
Datum i mesto rođenja	06.11.1987. godine u Nišu
Sadašnje zaposlenje	Univerzitet u Nišu Elektronski fakultet, Niš Katedra za automatiku
<b>II Doktorska disertacija</b>	
Naslov	Upravljanje dinamičkim sistemima primenom adaptivnih ortogonalnih neuronskih mreža
Broj stranica	180
Broj slika	87
Broj tabela	29
Broj bibliografskih jedinica	152
Ustanova i mesto gde je disertacija urađena	Univerzitet u Nišu, Elektronski fakultet, Niš
Naučna oblast	Elektrotehničko i računarsko inženjerstvo
Uža naučna oblast	Automatika
UDK broj	(681.325:531.39):004.32.26
Mentor	Prof. dr Dragan Antić, redovni profesor
<b>III Ocena i odbrana</b>	
Datum prijave teme disertacije	28.10.2015. godine
Datum javne prezentacije teme za doktorsku disertaciju	16.12.2015. godine
Broj odluke i datum prihvatanja teme disertacije	07/03-042/15-004 22.12.2015. godine
Komisija za ocenu podobnosti teme disertacije	1. Dragan Antić, redovni profesor, Univerzitet u Nišu, Elektronski fakultet 2. Vlastimir Nikolić, redovni profesor, Univerzitet u Nišu, Mašinski fakultet 3. Darko Mitić, vanredni profesor, Univerzitet u Nišu, Elektronski fakultet 4. Marko Milojković, docent, Univerzitet u Nišu, Elektronski fakultet 5. Sreten Stojanović, redovni profesor, Univerzitet u Nišu, Tehnološki fakultet
Komisija za odbranu disertacije	1. Dragan Antić, redovni profesor, Univerzitet u Nišu, Elektronski fakultet 2. Vlastimir Nikolić, redovni profesor, Univerzitet u Nišu, Mašinski fakultet 3. Darko Mitić, vanredni profesor, Univerzitet u Nišu, Elektronski fakultet 4. Marko Milojković, docent, Univerzitet u Nišu, Elektronski fakultet 5. Sreten Stojanović, redovni profesor, Univerzitet u Nišu, Tehnološki fakultet
Datum odbrane	

## Zahvalnica

Želeo bih pre svega da izrazim zahvalnost svom mentoru prof. dr Đaganu Antiću na konstantnom podsticaju, stručnoj pomoći i podršci od 2011. godine, i upisivanja doktorskih studija, pa do završetka mog školovanja i izrade doktorske disertacije. Izuzetnu zahvalnost dugujem i kolegama doc. dr Marku Milojkoviću i doc. dr Saši Nikoliću koji su mi pružili nemerljivu pomoć prilikom obavljenih naučnih istraživanja i pisanja disertacije. Zahvaljujem se i ostalim kolegama sa Katedre za automatiku na podršci, pomoći i pozitivnoj energiji koju su mi pružili tokom pisanja disertacije. Bez svih njih, svakako da ne bih bio u stanju da ovaj rad završim na dobar i kvalitetan način.

Ogromnu zahvalnost dugujem svojim roditeljima na bezrezervnoj ljubavi i podršci koju su mi pružili svih ovih godina, što su me odškolovali, naučili pravim životnim vrednostima i omogućili sve uslove za jedan srećan život. Rezultat tog srećnog života je i ova doktorska disertacija.

Svim svojim prijateljima dugujem zahvalnost što su uvek bili tu za mene kada je trebalo, za sve lepe trenutke koje su mi pružili i na svemu onome kroz šta smo zajedno prolazili. Bez takvih prijatelja danas ne bih bio čovek kakav jesam, na privatnom a i na profesionalnom planu.

Miki

## **Rezime**

### **Upravljanje dinamičkim sistemima primenom adaptivnih ortogonalnih neuronskih mreža**

Cilj istraživanja doktorske disertacije je upravljanje dinamičkim sistemima upotrebot novih tipova ortogonalnih endokrinih neuronskih mreža u cilju poboljšanja performansi sistema. Opisane su standardne veštačke neuronske mreže, njihov istorijski razvoj i osnovni tipovi učenja. Dalje, predstavljene su mogućnosti primene neuronskih mreža u okviru upravljačkih logika dinamičkih sistema, kao i trenutno stanje razvoja ortogonalnih i endokrinih neuronskih mreža. Analizirana je upotreba standardne neuronske mreže sa *backpropagation* tipom učenja za poboljšanje performansi laboratorijskog modela servo sistema. Takođe, predstavljena je metoda za selekciju i optimizaciju trening podataka, kao efikasan način preprocesiranja informacija u cilju poboljšanja neuronske mreže.

Dat je detaljan opis ortogonalnih funkcija kao i načini implementacije endokrinog faktora u okviru standardnih neuronskih mreža. Implementacijom ortogonalnih funkcija za aktivaciju neurona izvršena je provera njihove upotrebljivosti pri upravljanju dinamičkim sistemima. Laboratorijski model magnetnog levitatora upotrebljen je za testiranje projektovane ortogonalne neuronske mreže. Dalje, realizovana je endokrina ortogonalna neuronska mreža zasnovana na biološkim procesima ekscitacije i inhibicije. Provera performansi mreže izvršena je testiranjem njenih prediktivnih sposobnosti pri radu sa sekvencama vremenskih podataka.

Završna istraživanja u disertaciji odnose se na razvoj hibridnih sistema. Realizovani adaptivni endokrini neuro-fazi hibridni sistem testiran je kroz modeliranje laboratorijskog servo sistema. Druga hibridna struktura, zasnovana na kombinaciji ortogonalne endokrine neuronske mreže i ortogonalnog endokrinog neuro-fazi hibridnog sistema, projektovana je s ciljem simbioze pozitivnih karakteristika pojedinačnih mreža. Verifikacija rada ove strukture izvršena je njenom upotrebot za podešavanje parametara PID regulatora.

**Ključne reči:** neuronska mreža, ANFIS, ortogonalne funkcije, endokrini faktor

## **Summary**

### **Control of dynamical systems by using adaptive orthogonal neural networks**

The goal of the research in the PhD dissertation is control of dynamical systems by using new types of orthogonal endocrine neural networks, in order to improve their performances. Standard artificial neural networks are described, as well as their historical development and basic types of learning algorithms. Further, possibilities for neural networks applicability within control logic of dynamical systems are presented, as well as the current state of the art of orthogonal and endocrine neural networks. Performance improvement of the laboratory model of a servo system by using a standard neural network with the backpropagation type of learning is analyzed. In addition, a method for selection and optimization of training data, as an efficient way of information preprocessing for the purpose of improving performances of a neural network, is presented.

A detailed description of orthogonal functions and implementation methods of endocrine factors inside standard neural networks are provided. By implementation of orthogonal activation functions of neurons, verification of their applicability in control of dynamical systems was performed. The laboratory model of the magnetic levitation system was used to test the designed orthogonal neural network. Furthermore, the endocrine orthogonal neural network based on the biological processes of excitation and inhibition is designed. Network performance checkup is performed by testing its predictive abilities when working with time series data.

Final dissertation researches refer to development of hybrid systems. The implemented adaptive endocrine neuro-fuzzy hybrid system is tested through modeling of a laboratory servo system. Other hybrid structure, based on a combination of an orthogonal endocrine neural network and an orthogonal endocrine neuro-fuzzy hybrid system, is designed with the aim to form symbiosis of the positive characteristics of the individual networks. Verification of this structure was performed by using it for PID controller parameters adjustments.

**Keywords:** neural network, ANFIS, orthogonal functions, endocrine factor

# Sadržaj

<b>Uvod .....</b>	- 1 -
Ciljevi istraživanja.....	- 1 -
Naučni doprinosi .....	- 1 -
Organizacija doktorske disertacije .....	- 3 -
Naučne publikacije .....	- 4 -
<b>1 Osnove neuronskih mreža .....</b>	- 6 -
1.1 Istorijski razvoj veštačkih neuronskih mreža .....	- 6 -
1.2 Biološke neuronske mreže .....	- 9 -
1.3 Veštačke neuronske mreže .....	- 12 -
1.3.1 Model veštačkog neurona .....	- 12 -
1.3.2 Umrežavanje perceptronu i odabir potrebne strukture neuronske mreže.....	- 20 -
1.3.3 Modeli veštačkih neuronskih mreža.....	- 22 -
1.4 Algoritmi i parametri učenja perceptronu. Treniranje neuronskih mreža.	
<i>Backpropagation</i> model neuronske mreže .....	- 25 -
1.4.1 Algoritmi učenja perceptronu.....	- 25 -
1.4.2 Parametri algoritama učenja neuronskih mreža – stopa učenja i momentum faktor .....	- 37 -
1.4.3 <i>Backpropagation</i> neuronska mreža.....	- 40 -
<b>2 Motivacija za upotrebu veštačkih neuronskih mreža u upravljanju dinamičkim sistemima .....</b>	- 50 -
2.1 Primena veštačkih neuronskih mreža u upravljanju.....	- 50 -
2.2 Trenutno stanje razvoja ortogonalnih i endokrinih neuronskih mreža.....	- 56 -
2.2.1 Ortogonalne neuronske mreže (ONN) .....	- 56 -
2.2.2 Endokrine neuronske mreže .....	- 59 -
2.2.3 Složene ortogonalno-endokrine strukture neuronskih mreža.....	- 60 -
<b>3 Upotreba standardne neuronske mreže za poboljšanje performansi sistema .....</b>	- 62 -
3.1 Procedura projektovanja observera stanja.....	- 63 -
3.2 Regulator promenljive strukture .....	- 65 -
3.3 Servo sistem sa implementiranim regulatorom promenljive strukture .....	- 68 -
3.4 Projektovanje i implementacija veštačke neuronske mreže u upravljačku logiku servo sistema .....	- 73 -
3.5 Eksperimentalni rezultati i analiza rada servo sistema sa implementiranim <i>feedforward</i> neuronskom mrežom .....	- 76 -

<b>4 Metoda za selekciju i optimizaciju ulaznih parametara veštačke neuronske mreže .....</b>	- 81 -
4.1 Upotreba veštačkih neuronskih mreža u ekonomskim sistemima .....	- 81 -
4.2 Ekonomski parametri i PCA ( <i>Principal Component Analysis</i> ) metoda .....	- 82 -
4.3 Rezultati primene PCA metode .....	- 85 -
4.4 Međusobne zavisnosti i procedura formiranja ulaznih vektora.....	- 89 -
4.5 Projektovanje neuronske mreže i simulacioni rezultati.....	- 91 -
<b>5 Upotreba ortogonalnih funkcija u neuronskim mrežama .....</b>	- 93 -
5.1 Ortogonalne funkcije.....	- 93 -
5.1.1 Generalizacija kvazi – ortogonalnih polinoma Ležandrovog tipa .....	- 93 -
5.1.2 Čebiševljevi polinomi prve vrste .....	- 97 -
5.1.3 Kompleksne racionalne funkcije – ortogonalne trigonometrijske funkcije .....	- 98 -
5.2 Implementacija ortogonalnih aktivacionih funkcija unutar standardnih neuronskih mreža .....	- 100 -
5.2.1 LQ upravljanje i implementacija standardnih neuronskih mreža u upravljačku logiku magnetnog levitacionog sistema (MLS-a) .....	- 101 -
5.2.2 Realizacija ortogonalnih polinama za potrebe formiranja neuronske mreže .....	- 105 -
5.2.3 Projektovanje i primena ortogonalne neuronske mreže na MLS. Eksperimentalni rezultati.....	- 107 -
<b>6 Projektovanje endokrine neuronske mreže bazirane na postsinaptičkom potencijalu.....</b>	- 110 -
6.1 Endokrine neuronske mreže .....	- 110 -
6.2 Predikcija vremenskih sekvenci podataka upotrebom ortogonalnih endokrinskih neuronskih mreža baziranih na postsinaptičkim potencijalima.....	- 113 -
6.2.1 Veštački endokrini sistemi i postsinaptički potencijali .....	- 114 -
6.2.2 Projektovanje ortogonalne endokrine neuronske mreže zasnovane na postsinaptičkim potencijalima (OENNPP) .....	- 115 -
6.2.3 Simulacije na računaru i eksperimentalni rezultati .....	- 121 -
<b>7 Adaptivni endokrini ortogonalni ANFIS .....</b>	- 126 -
7.1 Generalizovani ortogonalni polinomi.....	- 127 -
7.2 Ortogonalni endokrini ANFIS (OEANFIS) .....	- 127 -
7.3 Modeliranje servo sistema korišćenjem OEANFIS-a .....	- 129 -
<b>8 Projektovanje hibridne strukture OENN-OEANFIS za podešavanje parametara PID regulatora .....</b>	- 134 -
8.1 Konfiguracija OENN-OEANFIS hibridne strukture.....	- 136 -
8.1.1 Endokrina neuronska mreža.....	- 138 -

8.1.2 Ortogonalne funkcije.....	- 138 -
8.1.3 Struktura ortogonalne endokrine neuronske mreže.....	- 138 -
8.1.4 Struktura OEANFIS-a.....	- 141 -
8.1.5 Inicijalizacija OENN-OEANFIS strukture .....	- 142 -
8.2 Optimizacija PID parametara korišćenjem OENN-OEANFIS strukture .....	- 144 -
8.3 Eksperiment na laboratorijskom modelu 3D krana .....	- 146 -
8.4 Eksperimentalni rezultati.....	- 148 -
<b>Zaključak .....</b>	<b>- 154 -</b>
<b>Doprinosi doktorske disertacije .....</b>	<b>- 157 -</b>
<b>Literatura .....</b>	<b>- 158 -</b>
<b>Kratka biografija autora .....</b>	<b>- 172 -</b>
<b>Spisak referenci autora .....</b>	<b>- 173 -</b>

# **Uvod**

## **Ciljevi istraživanja**

Veštačke neuronske mreže predstavljaju moćan alat za analizu podataka, predikciju, prepoznavanje oblika, optimizaciju, različite tipove upravljanja itd. Kao važna karakteristika izdvaja se njihova sposobnost učenja na osnovu kojeg postaju sposobne da reše probleme za koje nisu bile direktno obučene. Cilj naučnog istraživanja obuhvaćenog doktorskom disertacijom biće razvoj novih adaptivnih osobina neuronskih mreža koje će uspeti da poboljšaju performanse mreža i neuro-fazi sistema. Poseban akcenat biće na razvoju endokrinih adaptivnih neuronskih mreža i endokrinih adaptivnih neuro-fazi hibridnih sistema (ANFIS-a), uz upotrebu ortogonalnih aktivacionih funkcija unutar njihovih struktura.

U disertaciji će endokrino adaptivno dejstvo biti ostvareno implementacijom veštačkog hormonalnog uticaja unutar postojećih struktura ortogonalnih neuronskih mreža i ANFIS-a. Modifikovani sistemi biće sposobni za veću fleksibilnost i adaptaciju na uticaje spoljašnje sredine. Upotreba novih adaptivnih faktora bi trebalo da pruži tačnije predikcione rezultate, stabilizaciono dejstvo i bolje performanse u poređenju sa rezultatima koje daju konvencionalne mreže. Takođe, biće predložena univerzalna metoda pripreme trening podataka neuronske mreže s ciljem početne optimizacije i sistematizacije. Dugoročni cilj disertacije je da stvari dobru polaznu osnovu za nova istraživanja u oblasti endokrinih neuronskih mreža, sa zadatkom daljeg unapređenja performansi postojećih mreža.

## **Naučni doprinosi**

Važan doprinos disertacije predstavlja nova univerzalna metoda optimizacije trening podataka kao neophodnog koraka za uspešno modeliranje neuronskim mrežama. Očekivani rezultati biće brži i efikasniji rad različitih tipova neuronskih mreža i mogućnost primene na različite tipove trening podataka. Dalje, biće predstavljena implementacija ortogonalnih aktivacionih funkcija unutar veštačkih neuronskih mreža. Opravdanost upotrebe ortogonalnih funkcija biće ispitana na laboratorijskoj maketi magnetnog levitatora. Biće pokazan pozitivan uticaj ortogonalnih funkcija na pozicionu stabilizaciju objekta tokom levitiranja. Rezultati će pokazati i da upotreba ortogonalnih aktivacionih funkcija poboljšava levitacioni opseg kretanja objekta prilikom dvopozicione levitacije, u odnosu na levitacione performanse koje pružaju

standardne upravljačke strukture. Takođe, biće analizirana osobina ortogonalnosti da povoljno utiče na dinamiku procesa i uzrokuje brže vreme odziva upravljačkog sistema.

Kao doprinos u oblasti endokrinih neuronskih mreža biće predstavljen nov način regulisanja dejstva hormonalnog efekta uvođenjem adaptivnog parametra osetljivosti. Parametar osetljivosti je u dosadašnjim istraživanjima definisan kao unapred zadata konstantna vrednost. Cilj je realizovati mrežu kod koje bi se stepen osetljivosti menjao na osnovu unutrašnjih stanja mreže, kompleksnosti podataka koje mreža obrađuje i uticaja spoljašnje sredine. Mogućnosti primene adaptivnog hormonalnog efekta biće pokazane i njegovom implementacijom unutar strukture ANFIS-a. Eksperimenti na laboratorijskoj maketi modularnog servo DC sistema pokazaće značajno unapređenje performansi, upotrebom endokrinih hibridnih sistema. Očekivani rezultat biće regulacija endokrinog efekta prilikom promena u spoljašnjoj sredini, a sve sa svrhom stabilnog i preciznog rada endokrine ortogonalne neuronske mreže u okviru upravljačke logike sistema. Na kraju, biće predstavljeno hibridno intelligentno rešenje za *online* podešavanje parametara PID regulatora zasnovano na kombinovanju ortogonalne endokrine neuronske mreže (OENN) i ortogonalnog endokrinog ANFIS-a (OEANFIS-a). Zadatak hibridne strukture biće minimizacija poremećaja sistema na koje konvencionalni PID regulator ne može uticati.

Glavni doprinos predložene doktorske disertacije predstavlja razvoj ortogonalnih neuronskih mreža i ANFIS-a koji poseduju adaptivno dejstvo u vidu endokrinog hormonalnog efekta. Za ostvarenje postavljenih ciljeva biće urađeno sledeće:

- realizacija nove univerzalne metode optimizacije trening podataka kao neophodnog koraka za uspešno modeliranje neuronskim mrežama,
- projektovanje standardne neuronske mreže sa implementiranim ortogonalnim aktivacionim funkcijama,
- projektovanje ortogonalne endokrine neuronske mreže zasnovane na adaptivnom parametru osetljivosti,
- realizacija ortogonalnog endokrinog ANFIS-a,
- realizacija hibridnog intelligentnog sistema baziranog na kombinaciji ortogonalne endokrine neuronske mreže i ortogonalnog endokrinog ANFIS-a,
- verifikovanje svih projektovanih modela intelligentnog upravljanja računarskim simulacijama i laboratorijskim eksperimentima,
- upoređivanje rezultata ostvarenih korišćenjem projektovanih modela sa rezultatima koji se dobijaju upotrebom postojećih neuronskih mreža,
- predstavljanje sveobuhvatne analize dobijenih rezultata.

## Organizacija doktorske disertacije

Disertacija je organizovana u 8 poglavlja. U prvom poglavlju predstavljena je biološka neuronska mreža i opisani su osnovni principi njenog funkcionisanja. Dat je način matematičke reprezentacije protoka signala kroz mrežu na nivou pojedinačnog biološkog neurona čime je postavljen osnov za razvoj veštačkog neurona. Takođe, u poglavlju je dat detaljan osvrt na istoriju razvoja veštačkih neuronskih mreža od četrdesetih godina 20. veka do današnjice. Uvedena je formalizacija komponenti veštačkog neurona, predstavljeni su elementarni modeli neurona, i konačno, osnovni modeli veštačkih neuronskih mreža. Poglavlje se završava detaljnim prikazom popularnih algoritama učenja mreža. Drugo poglavlje se sastoji iz dva dela. U prvom je dat osvrt na mogućnosti primene neuronskih mreža u upravljačkim aplikacijama (od predikcije i optimizacije do upravljanja sistemima u realnom vremenu) i navedene su osnovne karakteristike standardnih neuronskih mreža. Drugi deo poglavlja daje prikaz trenutnog stanja razvoja ortogonalnih i endokrinih neuronskih mreža kao istraživačke osnove ove doktorske disertacije. Prikazane su karakteristike ovih mreža, data je njihova upotrebnost i osvrt na dosadašnja istraživanja u kojima su bile realizovane. U trećem poglavlju je prikazana eksperimentalna upotreba standardne neuronske mreže za poboljšanje performansi realnog sistema. Iskorišćena je standardna *feedforward* mreža za unapređenje estimacije brzine jednosmernog motora. Eksperimentalno je pokazano da Luenbergerov observer stanja loše estimira brzinu kada se na osovini motora nalazi teret velikog momenta inercije. Implementacijom standardne neuronske mreže u upravljačku logiku sistema performanse observera su značajno unapređene: estimacija brzine u ustaljenom stanju je postala preciznija i smanjena je greška estimacije tokom prelaznih procesa. U četvrtom poglavlju je data metoda za selekciju i optimizaciju trening podataka veštačke neuronske mreže. Metoda je pokazala veliki uticaj preprocesiranja podataka na povećanje brzine rada mreže i smanjenje potrebnog vremena za njenu obuku. Takođe, princip optimizacije je pokazao univerzalnost po pitanju primene na sređivanje podataka koji će se koristiti za trenažne procese različitih tipova mreža. U poglavlju 5 su definisane i matematički predstavljene ortogonalne funkcije koje će biti korišćene u disertaciji. Takođe, prikazana je metodologija za njihovu implementaciju unutar standardnih neuronskih mreža gde je kao objekat upravljanja iskorišćen laboratorijski model magnetnog levitacionog sistema. U poglavlju 6 detaljno su prikazane endokrine neuronske mreže. Takođe, projektovan je novi tip endokrine neuronske mreže zasnovan na adaptivnom parametru osetljivosti. Pri realizaciji novog tipa mreže iskorišćeni su biološki principi ekscitacije i inhibicije. Time se pokazalo da i dalji razvoj veštačkih neuronskih mreža može biti

vezan za imitaciju bioloških procesa. Poglavlje 7 se sastoji iz dva dela. U prvom je dat prikaz neuro-fazi hibridnih sistema – ANFIS-a. ANFIS predstavlja strukturu zasnovanu na kombinaciji fazi logike i neuronske mreže, čime se obezbeđuju pozitivne osobine obe strukture. U drugom delu poglavlja je ANFIS iskorišćen kao baza za nadogradnju – za uvođenje ortogonalnih funkcija i endokrinog faktora u okviru defazifikacionog sloja mreže. U 8. poglavlju je razvijena složena struktura koja se bazira na upotrebi ortogonalnih endokrinih neuronskih mreža (standardne mreže i ANFIS-a). Obe mreže su zasnovane na Čebiševljevim funkcijama i prisustvu endokrinih faktora. Zadatak strukture je *online* podešavanje parametara PID regulatora u cilju minimizacije poremećaja sistema. Eksperimenti sa realizovanom hibridnom strukturu obavljeni su na laboratorijskom modelu 3D krana. Na kraju, izvedeni su zaključci i predstavljeni su mogući dalji pravci istraživanja zasnovani na rezultatima prikazanim u disertaciji.

Važno je napomenuti da je većina rezultata predstavljenih u ovoj disertaciji verifikovana u naučnim publikacijama u domaćim i međunarodnim časopisima kao i zbornicima međunarodnih i domaćih konferencija.

## Naučne publikacije

U nastavku je prikazana lista naučnih publikacija objavljenih za potrebe realizacije ove doktorske disertacije.

1) Dragan Antić, **Miroslav Milovanović**, Staniša Perić, Saša Nikolić, Marko Milojković, “Input Data Preprocessing Method for Exchange Rate Forecasting via Neural Network”, vol. 11, no. 4, pp. 597–608, *Serbian Journal of Electrical Engineering*, December 2014. (**M52**)

2) **Miroslav B. Milovanović**, Dragan S. Antić, Miodrag D. Spasić, Saša S. Nikolić, Staniša Lj. Perić, Marko T. Milojković, “Improvement of DC Motor Velocity Estimation Using Feedforward Neural Network”, *Acta Polytechnica Hungarica*, vol. 12, no. 6, pp. 107–126, ISSN: 1785-8860, (Doi No: 10.12700/APH.12.6.2015.6.7), Publisher: Óbuda University, Hungary, November 2015. (**M23**)

3) Marko T. Milojković, Dragan S. Antić, **Miroslav B. Milovanović**, Saša S. Nikolić, Staniša Lj. Perić, Muhanad Almawlawe, “Modeling of Dynamic Systems Using Orthogonal Endocrine Adaptive Neuro-Fuzzy Inference Systems”, *Journal of Dynamic Systems Measurement and Control*, vol. 137, no. 9, ISSN: 1528-9028, (Doi No:

<http://dx.doi.org/10.1115/1.4030758>), **Publisher: American Society of Mechanical Engineers**, July 2015. (M23)

4) **Miroslav B. Milovanović**, Dragan S. Antić, Marko T. Milojković, Saša S. Nikolić, Staniša Lj. Perić, Miodrag D. Spasić, “Adaptive PID Control Based on Orthogonal Endocrine Neural Network”, Neural Networks, vol. 84, pp. 80-90, Doi No: <http://dx.doi.org/10.1016/j.neunet.2016.08.012>), **Publisher: Elsevier**. December 2016. (M21a)

5) **Miroslav Milovanović**, Dragan Antić, Marko Milojković, Saša S. Nikolić, Miodrag Spasić, Staniša Perić, “Time Series Forecasting with Orthogonal Endocrine Neural Network Based on Postsynaptic Potentials”, Journal of Dynamic Systems, Measurement, and Control, vol. 139, no. 4, pp. 041006-1–041006-9, DS-15-1656, Print ISSN: 0022-0434, (Doi No: <http://dx.doi.org/10.1115/1.4035090>), **Publisher: The American Society of Mechanical Engineers**, April 2017. (M23)

6) **Miroslav B. Milovanović**, Dragan S. Antić, Saša S. Nikolić, Staniša Lj. Perić, Marko T. Milojković, Miodrag D. Spasić, “Neural Network Based on Orthogonal Polynomials Applied in Magnetic Levitation System Control”, Electronics and Electrical Engineering, vol. 23, no. 3, pp. 24–29, Print ISSN: 1392-1215, (Doi No: <http://dx.doi.org/10.5755/j01.eie.23.3.18327>), Publisher: Kaunas University of Technology, June 2017. (M23)

7) **Miroslav B. Milovanović**, Dragan S. Antić, Milena N. Rajić, Pedja M. Milosavljević, Ana Pavlović, Cristiano Fragassa, “Wood resource management using an endocrine NARX neural network”, European Journal of Wood and Wood Products, (Doi No: <https://doi.org/10.1007/s00107-017-1223-6>), Publisher: Springer Berlin Heidelberg, 2017, accepted. (M21)

# 1 Osnove neuronskih mreža

## 1.1 Istorijski razvoj veštačkih neuronskih mreža

Ljudska snaga kao osnovni pokretač svih proizvodnih ciklusa je, nakon industrijske revolucije u osamnaestom veku, intenzivno menjana snagom baziranim na mašinskom radu. Do zamene ljudske inteligencije veštačkom čekalo se do sredine 20-og veka. Inteligencija se može definisati na mnogo načina ali u opštem slučaju podrazumeva kompleksan skup mentalnih sposobnosti kao što su: zaključivanje, planiranje, rešavanje problema, apstraktno razmišljanje, razumevanje kompleksnih ideja, učenje iz iskustva, adaptiranje na nove situacije, kao i korišćenje stečenog znanja u interakciji sa okruženjem. Sa druge strane, veštačka inteligencija predstavlja pokušaj da se ljudska inteligencija na adekvatan način zameni mašinskom. Sistemi koji poseduju veštačku inteligenciju mogu imati sposobnosti adaptivnosti (prilagođavanje promenjenim uslovima rada), učenja (nadogradnja znanja o objektu upravljanja), autonomije (rešavanje nepredviđenih situacija bez spoljne pomoći), kao i da poseduju sposobnost rešavanja složenih problema kao što su upravljanje nelinearnim procesima, procesima sa raspodeljenim parametrima, itd.

Prvi konstruisani računari mogli su da manipulišu efikasno velikim bazama podataka na osnovu definisanih algoritama, ali nisu mogli da sami rezonuju i prilagođavaju se informacijama koje obrađuju. Tada se postavljalo pitanje da li će ikada biti razvijeni računari koji će moći sami da razmišljaju. Klasa problema koji zahtevaju inteligentno rasuđivanje uključuje obradu nepouzdanih i nekompletnih informacija, različite forme percepcije i učenja, aplikacije problema upravljanja, predikcije, klasifikacije i optimizacije... Veštačka inteligencija u opštem smislu bazira se na dva prilaza rešavanju problema. Prvi prilaz obuhvata takozvane „*knowledge based*“ sisteme, logičko rezonovanje, „*machine learning*“ tehnike, tehnike pretraživanja, „*natural language processing*“ (NLP) tehnike. Drugi prilaz razmatra veštačke neuronske mreže i zasnovan je na mikroskopskim biološkim modelima, osnovnim mehanizmima biološkog procesiranja informacija i interpretaciji rada biološkog mozga. Paralelno s istraživanjem modela neuronskih mreža istraživane su mogućnosti za njihovu primenu, kao i nove tehnologije kojima one mogu biti implementirane u okviru postojećih sistema. Istraživačke aktivnosti tokom razvoja mreža mogu se svrstati u neku od sledećih kategorija: razvoj modela koji simuliraju funkcionisanje bioloških neurona, razvoj struktura

neuronskih mreža i modela sinaptičkih veza, razvoj algoritama učenja, razvoj tehnologija implementacije i razvoj modela zasnovanih na praktičnoj primeni.

Trenutna znanja iz oblasti strukture i fiziologije biološkog neurona su rezultat stogodišnjeg istraživanja u ovoj oblasti. Još 1901. godine znalo se da se prenos signala može obavljati u oba pravca duž aksona, ali je utvrđeno i da način umrežavanja nervnih ćelija određuje smer prenosa podataka. Tada je bilo jasno da vezivanje neurona u mrežu znači i hijerarhijsku (slojevitu) vezu između njih. Hemijski prenos informacija bioloških sinapsi je intenzivno proučavan od 1920. do 1940. godine kada su utvrđene osnovne korelacije i mehanizmi protoka informacija kroz biološku neuronsku mrežu. Sledeće veliko otkriće biološkog neurona postignuto je 1950. godine kada su Emil du Bois-Reymond i Hermann von Helmholtz predstavili električnu prirodu nervnog impulsa. Tada su se početne pretpostavke o velikoj brzini impulsa pokazale kao netačne.

Istorija veštačkih neuronskih mreža počinje ranih 1940-ih godina sa razvojem elektronskih računara. Warren McCulloch i Walter Pitts su 1943. godine predstavili modele neuroloških mreža zasnovanih na prekidačima sa aktivacionim pragovima. Pokazali su da čak i ove jednostavne mreže imaju sposobnost emuliranja skoro svake logičke ili aritmetičke funkcije. Pri realizaciji su koristili jednostavan model neurona koji obrađuje informacije poput biološkog neurona – kroz sinaptičku i somatsku operaciju (o kojima će biti više reči u sledećem poglavlju). Ovaj elementarni model neurona nazvan je perceptronom. Ova dva naučnika su takođe smatrala da je povezivanjem velikog broja perceptronova u jednu funkcionalnu mrežu moguće modelirati biološki mozak čoveka. McCulloch i Pitts su već 1947. godine razvili praktičnu aplikaciju baziranu na veštačkim neuronskim mrežama – rešili su problem prepoznavanja oblika u prostoru. Donald Hebb je 1949. godine formulisao Hebbovo pravilo koje predstavlja osnovu skoro svakog algoritma učenja. Pravilo kaže da su konekcije između dva neurona jače kada su oba neurona aktivna istovremeno. Hebb je teoretski predstavio ovo pravilo ali nije mogao da ga verifikuje zbog nedostatka neuroloških istraživanja. Neuropsiholog Karl Lashley je 1950. godine potvrdio tezu da se skladištenje informacija u mozgu realizuje kao kod distribuiranih sistema gde je niz pojedinačnih sistema međusobno vezan u jednu celinu, s ciljem zajedničkog rešavanja problema. Teza je bila bazirana na eksperimentu koji je sproveden na pacovima: utvrđivana je njihova sposobnost pronalaženja izlaza iz labyrintha sa različitim stepenom uklonjenog nervnog tkiva iz njihovih glava. Pokazalo se da obim uklonjenog nervnog tkiva (a ne pozicija uklonjenog tkiva u mozgu) utiče na sposobnost biološkog mozga i na performanse koje živo biće može da pruži. Time je bila potvrđena teza distribuiranog prenosa i pohranjivanja podataka u biološkom mozgu.

Takozvano zlatno doba razvoja veštačkih neuronskih mreža započinje 1951. godine kada je Marvin Minsky napravio neuroračunar Snark sa sposobnošću automatskog ažuriranja težina. Odlikovao se velikom brzinom procesiranja i računanja ali tada nije bila u potpunosti poznata proračunska procedura koju on obavlja. Pet godina kasnije proistekla je ideja da se simuliranje rada mozga treba izvršiti počevši od imitacije (simuliranja) najmanje komponente mozga – neurona. Frank Rosenblatt i Charles Wightman su u periodu 1957-1958. godine razvili prvi uspešni neuroračunar Mark I Perceptron, koji je bio sposoban da prepoznae napisane jednostavne brojeve pomoću senzora rezolucije 20x20 piksela. Neuroračunar je radio na elektromehaničkom principu, pomoću 512 potenciometara pokretanih motorima (svaki potenciometar predstavlja jednu promenljivu). Rosenblatt je već 1959. godine opisao, formulisao i verifikovao različite tipove perceptronova. Opisao je slojeve neurona koji formiraju mrežu, prekidačke funkcije aktivacionih pragova i pravila učenja zasnovanih na prilagođavanju težinskih koeficijenata. Bernard Widrow i Marcian Hoff su predstavili 1960. godine ADALINE (*Adaptive Linear Neuron*) - brz i precizan sistem adaptivnog učenja koji je bio prva široko korišćena komercijalna veštačka neuronska mreža. Adaline se upotrebljavao kao komponenta analognih telefona za adaptivnu eho-filtraciju zvučnog signala u realnom vremenu. U to vreme, javlja se prvi put i delta pravilo učenja koje se pokazalo efikasnijim algoritmom od originalnog perceptron algoritma učenja. Delta pravilo se može predstaviti na sledeći način: ako je razlika između dobijenog i ispravnog rešenja velika, težinski koeficijenti se takođe menjaju u većim koracima. Sa druge strane, ako su koraci manji, korektivni faktor težina je takođe manji. Karl Steinbuch je 1961. godine predstavio tehničku realizaciju asocijativne memorije koja je bila osnova za kasniji razvoj asocijativne memorije neuronskih mreža. Marvin Minsky i Seymour Papert su 1969. godine publikovali matematičku analizu modela perceptrona gde su pokazali da on zapravo nije u mogućnosti da reši složenije probleme. Njihova publikacija je uticala na smanjenje popularnosti veštačkih neuronskih mreža, i demotivisala je istraživače za njihov dalji razvoj. Smatralo se da je oblast došla do razvojnog maksimuma, da je sama ideja simulacije ljudskog mozga precenjena i da će formiranje složenog modela neuronske mreže takođe pokazati iste nerešive probleme. Posledica ovakvih razmišljanja prouzrokovala je skoro kompletan prestanak istraživanja veštačkih neuronskih mreža u narednih 15 godina.

U periodu stagnacije razvoja neuronskih mreža ipak je ostalo zabeleženo nekoliko važnih otkrića. Teuvo Kohonen je 1972. godine predstavio model asocijativne memorije. Christoph von der Malsburg je 1973. godine realizovao model neurona koji je bio nelinearan i struktorno baziran na biološkom neuronu. Harvard Werbos je 1974. godine razvio Backpropagation algoritam učenja koji podrazumeva propagaciju greške mreže unazad. Novi algoritam učenja

je svoju popularnost doživeo tek deceniju kasnije. Naučnik Stephen Grossberg je svoj istraživački rad usmerio ka rešavanju problema učenja neuronske mreže koje ne podrazumeva uništavanje prethodno naučenih asocijativnosti pri usvajanju novih znanja. To je dovelo do razvoja modela adaptivnih rezonantnih teorija (ART modela). Teuvo Kohonen je 1982. godine predstavio samoorganizujuće Kohonenove mape kod kojih je pokušao da simulira mehanizme samoorganizacije biološkog mozga. Samoorganizacija polazi od toga da je pojedinačni biološki neuron često nedovoljan da pohrani čitavu dobijenu informaciju i tada je mozak zadužen da organizuje pamćenje informacije na nivou većeg broja međusobno povezanih neurona. Iste godine je John Hopfield razvio model takozvane Hopfield-ove mreže koja je inspirisana zakonima magnetizma. Miyake i Ito Fukushima su 1983. godine razvili model neuronske mreže pod nazivom Neocognitron koji je bio u stanju da prepozna rukom napisane karaktere i slova.

Doba renesanse naučne oblasti i velikog progresa koji traje i danas počinje pod uticajem Hopfield-a koji je, na ličnim rezultatima, ubedio mnoge istraživače o važnosti naučnog polja neuronskih mreža i velikim mogućnostima koje ipak ona može da pruži. On 1985. godine publikuje rad u kome predstavlja optimalni način za rešavanje problema „putujući prodavac“ upotrebom Hopfield-ove mreže (problem će biti predstavljen u narednom poglavlju). Udružena naučna zajednica pod imenom „*Parallel Distributed Processing Group*“ predstavila je upotrebu *backpropagation* algoritma učenja kao generalizaciju delta pravila. Nelinearno separabilni problemi su se u daljem razvoju neuronskih mreža pokazali kao rešivi višeslojnim perceptronima, čime su se negativne evaluacije Marvina i Minsky-ja iz 1969. godine pokazale kao apsolutno netačne. Od 1985. godine pa do danas razvijen je veliki broj različitih tipova neuronskih mreža, od kojih će neke biti detaljno obrađene u ovoj disertaciji.

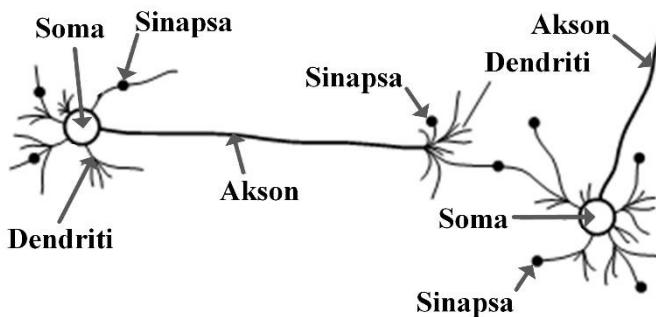
## **1.2 Biološke neuronske mreže**

Veštačka neuronska mreža predstavlja model mreže inspirisan biološkom neuronskom mrežom ljudskog mozga. Mozak se može smatrati kompleksnim, nelinearnim i paralelnim sistemom za obradu informacija. Sastoji se od skupa međusobno povezanih nervnih ćelija koje predstavljaju osnovne jedinice za obradu informacija – neurone. Da bi se uvideo značaj broja neurona koji je potreban za izvršavanje složenih operacija biće navedeno nekoliko primera karakterističnih za biološke organizme. Mrav poseduje oko  $10^4$  neurona u svom nervnom sistemu što mu omogućava formiranje svesti za povezivanjem u kompleksna socijalna okruženja kojima može pripadati i milion jedinki. Sa  $10^5$  neurona može se formirati nervni

sistem muve. Muve su u stanju da izbegavaju objekte u tri dimenzije, mogu naopako da se pozicioniraju i održavaju ravnotežu, poseduju senzorski sistem koji se sastoji od receptora na nogama i očiju. Pčela ima  $8 \cdot 10^5$  neurona što je dovoljno da poseduje sposobnost da proizvodi med. Pčele formiraju kolonije, imaju sjajne sposobnosti izviđanja i navigacije. Svet kičmenjaka počinje sa  $4 \cdot 10^6$  neurona, koliko poseduju miševi. Žaba ima  $15 \cdot 10^6$  neurona u svom nervnom sistemu i poseduje sposobnost da pliva, skače, obavlja zvučnu komunikaciju, locira muvu i uhvati je tokom njenog leta – za šta je potreban visok stepen preciznosti i planiranja kretanja. Pas ima  $16 \cdot 10^7$  neurona, a mačka  $3 \cdot 10^8$  nervnih jedinica. Ljudski mozak se sastoji od približno  $10^{11}$  neurona i 60 triliona međuneuronskih veza (sinapsi) što čoveku omogućava da govori, vrši apstrakciju pojmoveva, pamti, uči, pokazuje emocije, itd. Smatra se da najmanja funkcionalna jedinica (kolonija) u mozgu sadrži oko 4000 neurona. Kolonija je dovoljna za izražavanje emocije, stvaranje svesti o nekom pojmu, formiranje misli... Svaki neuron unutar kolonije poseduje veoma jednostavnu strukturu koja nema veliku moć obrade podataka (Slika 1.1). Međutim, skup ovakvih umreženih elemenata može obezbediti veliku proračunsku moć.

Osnovni elementi biološkog neurona su:

- soma – telo ćelije
- dendriti – ulazni kanali
- akson – jedan izlazni kanal
- sinapse – memorijски članovi biološke neuronske mreže



Slika 1.1 Biološka neuronska mreža

Propagiranje signala od jednog neurona do drugog izvršava se složenim elektrohemiskim reakcijama. Kada električni signal dođe na ulaze neurona, konvertuje se u hemijski signal pomoću neurotransmitera. Neurotransmiteri su supstance koje regulišu prenošenje električnih signala između nervnih ćelija. Ove supstance prelaze sinaptičku pukotinu i prenose

informacije do neurona, gde se nakon procesiranja ponovo konvertuju u električni signal. Neurotransmiteri se dele u dve grupe: na one koji stimulišu neuron, i one koji usporavaju ovu stimulaciju. U zavisnosti od njih, sinapse mogu propagirati snažan stimulišući signal, a takođe i signale koji nemaju uticaja na pobuđivanje neurona. U biološkim neuronima električni signali generišu se kao rezultat razlike koncentracija jona kalijuma i natrijuma. Hemiske supstance izlučene od strane sinapsi prouzrokuju promenu električnog potencijala tela ćelije. Kada potencijal dostigne potrebnii prag osetljivosti onda on postaje akcioni potencijal (električni puls) koji se propušta kroz izlazni kanal (akson). Dužina aksona u pojedinim slučajevima može biti i do 1m. Njegova karakteristika je da je električni izolovan kako bi bolje provodio električni signal. Puls se propagira unapred i dostiže sinapse drugog neurona prouzrokujući smanjenje ili povećanje njihovih potencijala. Dakle, obrada signala u jednom neuronu se može generalizovati i podeliti u dve etape:

- sinaptička etapa – u kojoj se svakom ulaznom signalu dodeljuje određena težina koja zavisi od vrednosti sinapsi kroz koje signal prolazi,
- somatska etapa – u kojoj se vrši akumuliranje svih ulaznih signala i upoređuje sumirana vrednost sa aktivacionim pragom. Ukoliko je ta vrednost veća od aktivacionog praga, na izlazu neurona generiše se impuls i šalje do drugih neurona.

Odlika bioloških neurona je da su u stanju da se prilagode i formiraju po potrebi nove međuneuronske veze. Nove veze se formiraju na mestima velikog protoka informacija čime se komunikacija poboljšava i veze u tom delu nervnog sistema ojačavaju. Takođe, biološki mozak poseduje mehanizam da obezbedi efikasnije učenje tako što čitave kolonije neurona mogu migrirati sa jednog mesta na drugo kako bi omogućile optimalno propagiranje informacija. Veze između neurona su takve da one koje propagiraju „tačne odgovore“ budu pojačane, dok one koje nose „netačne odgovore“ bivaju oslabljene kako bi se njihov uticaj na mrežu smanjio. Upravo je to razlog zbog koga neuronska mreža ima mogućnost učenja kroz iskustvo. Učenje je ujedno i osnovna karakteristika biološke neuronske mreže. Jednostavnost procesa učenja bioloških mreža je i doveo do pokušaja imitiranja njihovog rada pomoću računara.

## 1.3 Veštačke neuronske mreže

### 1.3.1 Model veštačkog neurona

Glavne prednosti bioloških neuronskih mreža u odnosu na računarske sisteme su jednostavnost procesorskih jedinica, distribuirano procesiranje informacija i paralelizam koji mreže mogu ostvariti. Takođe, mreža ima sposobnost učenja i poseduje veću robustnost nego računarski sistem. Ono što se može okarakterisati kao prednost računara je definisano okruženje u okviru koga računar funkcioniše i velika procesorska brzina. Njihova detaljna komparacija predstavljena je u tabeli 1.1. Težnja za realizacijom veštačke neuronske mreže bila je motivisana željom da se navedene prednosti biološkog nervnog sistema ostvare formiranjem veštačkog modela neuronske mreže. Modeliranje biološkog nervnog sistema i formiranje veštačkog podrazumeva mnoga pojednostavljenja ali i zadržavanje osnovnih principa njegovog funkcionisanja.

Tabela 1.1 Poređenje računarskog i nervnog sistema

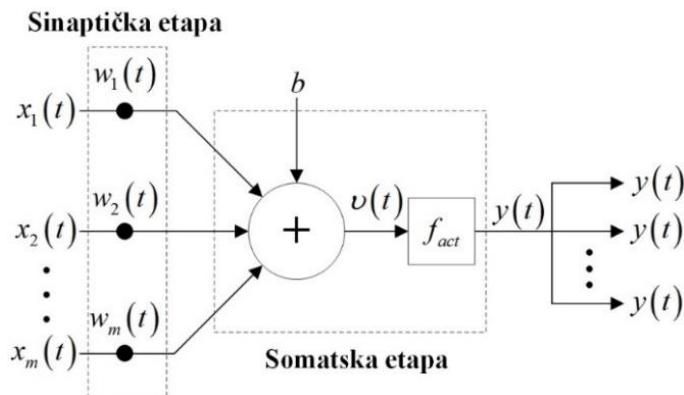
	<i>Računar</i>	<i>Biološka neuronska mreža</i>
<i>Memorija</i>	Odvojena od procesora Lokalizovana	Integrисана u procesoru Distribuirana
<i>Procesor</i>	Kompleksan Velika brzina ( $10^8 \text{ Hz}$ ) Jedan ili par procesora Brzina signala ( $10^8 \text{ m/s}$ )	Jednostavan Mala brzina ( $10^2 \text{ Hz}$ ) Veliki broj procesora ( $10^4$ ) Brzina signala ( $1 \text{ m/s}$ )
<i>Računanje</i>	Centralizovano Redno Pohranjeni programi	Distribuirano Paralelno Samooobuka
<i>Pouzdanost</i>	Veoma osetljiv	Robustna
<i>Okruženje</i>	Definisano Ograničeno	Loše definisano Bez ograničenja

Biološki neuron u proseku prima između  $10^3$  i  $10^4$  informacija sa drugih neurona. Zbog toga se veštački neuron formira sa više ulaza koje je moguće predstaviti u vektorskome obliku. Izlaz biološkog neurona je skalar, što znači da se sastoji od jedinstvene vrednosti. Skalarnom vrednošću biće predstavljen i izlaz veštačkog neurona. Dalje, biološke sinapse menjaju vrednosti ulaznih signala na osnovu njihovih pojedinačnih karakteristika. U veštačkim neuronskim mrežama ulazne vrednosti su pretprocesirane i multiplikovane težinama koje ih karakterišu. Biološki neuron sumira ulazne električne signale da bi generisao impuls na izlazu, dok se kod veštačkih mreža ovo realizuje pomoću vrednosti sume ulaza koja se poredi sa aktivacionim pragom i, ukoliko je uslov za aktiviranje zadovoljen, na izlazu će se generisati

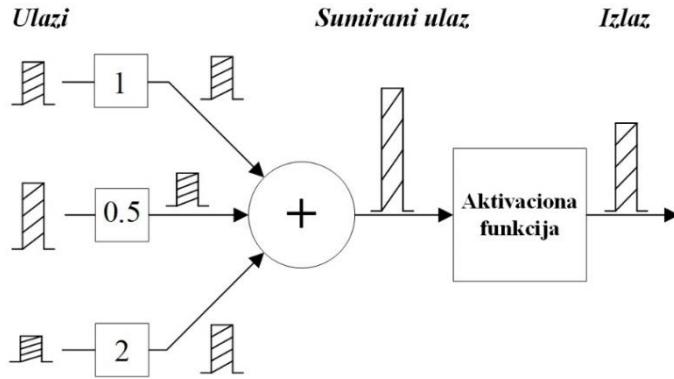
signal. Ulazno-izlazna nelinearna karakteristika bioloških neurona ostvarena je i kod veštačkih, primenom adekvatnih aktivacionih funkcija o kojima će kasnije biti više reči. Biološki neuroni favorizuju ili minimizuju značaj pojedinih ulaznih signala jednog neurona na osnovu hemijskih procesa koji se obavljaju u sinaptičkom procepu. Veštački neuroni takođe dobijaju tu osobinu uvođenjem varijabilnih težinskih koeficijenata na ulaze neurona, čime se realizuje simulacija elektro-hemijskih procesa. To omogućava efikasnost veštačke mreže i sposobnost da uči i propagira „tačne“ odgovore i potrebne signale. Na osnovu imitiranja principa funkcionisanja biološkog neurona formiran je perceptron kao osnovni oblik veštačkog neurona.

### 1.3.1.1 Osnovna struktura perceptrona

Elementarni model neurona koji su razvili McCulloh i Pitts (1943. i 1947. godine) naziva se perceptron (Slika 1.2). Model perceptrona i danas služi kao osnovna jedinica veštačkih neuronskih mreža. Perceptron je dobio naziv u 50-im godinama prošloga veka kada je sličan model korišćen za modeliranje percepcije (opažanja). Najjednostavniji perceptron je binarni čiji generisani izlaz može imati dve moguće vrednosti ( $\{0, 1\}$  ili  $\{-1, 1\}$ ). Za realizaciju ovakvog perceptrona koriste se binarne (bipolarne) aktivacione funkcije. U strukturu perceptrona se pored bipolarnih mogu implementirati i linearne i nelinearne aktivacione funkcije i pomoću njih se po potrebi menjati opsezi vrednosti koje perceptron može generisati na izlazu. Upotrebljena vrednost perceptrona je u realizaciji logičkih operacija i rešavanju linearno separabilnih problema o kojima će više reći biti kasnije. Ulazi perceptrona označeni su sa  $x_1(t), x_2(t), \dots, x_m(t)$ , sinapse (težinski koeficijenti) sa  $w_1(t), w_2(t), \dots, w_m(t)$ ,  $b$  predstavlja aktivacioni prag,  $v(t)$  je sumirano stanje svih ulaznih signala opterećenih sinaptičkim težinama,  $f_{act}$  predstavlja zadatu aktivacionu funkciju i  $y$  je izlaz iz perceptrona koji se propagira napred do narednih neurona.



Slika 1.2 Grafički prikaz perceptrona



Slika 1.3 Proces obrade signala perceptronu

Idealizovani proces obrade signala u perceptronu je predstavljen na slici 1.3. Svaki ulazni signal se multiplikuje odgovarajućim težinskim koeficijentom. Nakon toga se formira ukupna suma multiplikovanih ulaznih signala koja se dovodi na ulaz aktivacione funkcije. U zavisnosti od odabrane funkcije i aktivacionog praga neuron generiše izlaznu vrednost. Perceptron se može predstaviti u matematičkom obliku na osnovu slike 1.2. Najpre, potrebno je izračunati sumirano stanje svih ulaznih signala  $v$ :

$$\begin{aligned} v(t) &= x_1(t)w_1(t) + x_2(t)w_2(t) + \dots + x_m(t)w_m(t) = \\ &= \sum_{i=1}^m x_i(t)w_i(t) \end{aligned} \quad (1.1)$$

Nakon poređenja signala  $v$  sa zadatim aktivacionog pragom ( $b$ ), koji je izražen jednom od ulaznih vrednosti  $x(t)$ , neuron će, u zavisnosti od implementirane funkcije ( $f_{act}$ ) formirati izlaznu vrednost neurona  $y$ :

$$y(t) = f_{act}(v(t)) \quad (1.2)$$

Model predstavljen u (1.1) se može zapisati i u vektorskom obliku ukoliko je:

$X(t) = [x_1(t), \dots, x_m(t)]^T$  - vektor ulaznih signala,

$W(t) = [w_1(t), \dots, w_m(t)]^T$  - vektor težinskih koeficijenata.

Tada važi:

$$v(t) = W^T(t) \cdot X(t) \quad (1.3)$$

Vektorski zapis može biti izuzetno značajan prilikom procesa optimizacije rada neuronskih mreža. Da bi se izvršilo sabiranje ulaznih parametara mreže iz (1.1) potrebno je formirati *for* petlju koja bi izvršila potrebno sumiranje zadatih elemenata kroz  $m$  iteracija:

$$\begin{aligned}
 v &= 0 \\
 \text{for } i &= 1:m \\
 v &= v + x(i) \cdot w(i) \\
 \text{end}
 \end{aligned} \tag{1.4}$$

Pri zapisu iz (1.3) dovoljna je operacija množenja vektora da bi se dobila potrebna vrednost  $v$ :

$$v = [w_1(t), \dots, w_m(t)] \cdot \begin{bmatrix} x_1(t) \\ \dots \\ x_m(t) \end{bmatrix}. \tag{1.5}$$

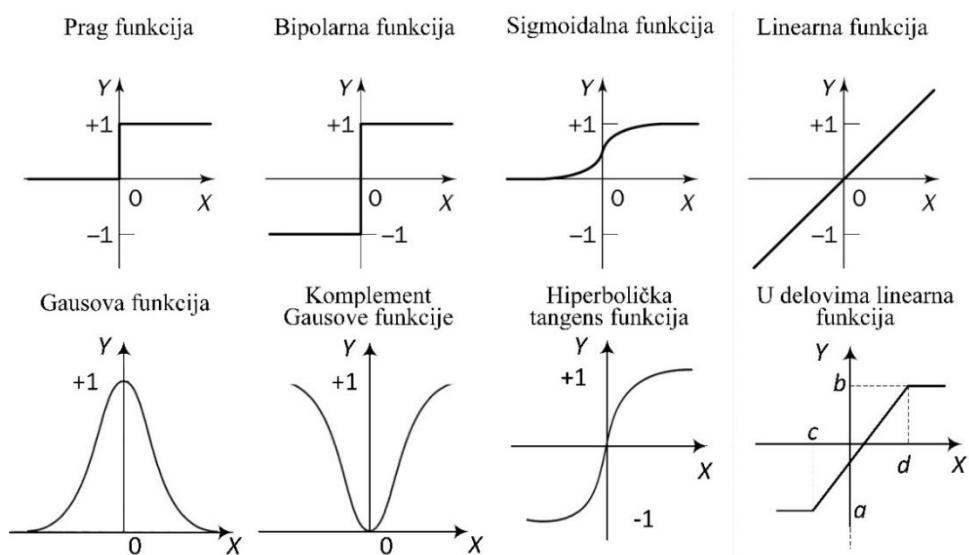
Na osnovu (1.4) i (1.5) jasno je da će obrada podataka pomoći računara biti efikasnija u slučaju upotrebe vektorskog zapisa gde se pri jednoj iteraciji izvrši potreban proces računanja, za razliku od  $m$  iteracija koliko je potrebno za jednačinu (1.1). Dalje, sumirano stanje  $v$  se obrađuje pomoći odabrane aktivacione funkcije. Neki od osnovnih tipova aktivacionih funkcija koji se mogu koristi za potrebe neuronskih mreža biće predstavljeni u sledećem poglavlju.

### 1.3.1.2 Tipovi aktivacionih funkcija

Neuron se smatra apstraktnim modelom biološkog neurona mozga pa aktivacione funkcije, u stvari, predstavljaju apstraktne modele elektromehaničkih signala. Reakcija neurona na ulazni signal zavisi od njegovog aktivacionog stanja (aktivnog ili neaktivnog). Ukoliko je neuron u aktivnom stanju generisće na izlazu odgovarajući signal, a ukoliko je neaktivan, izlaz neurona biće jednak nuli. Zavisno od aktivacione funkcije svaki neuron će u određenom opsegu biti aktivan (pobuđen). Neuron postaje aktivan ako suma svih njegovih ulaza premaši vrednost praga aktivacione funkcije koji ga karakteriše. Aktivaciona funkcija se najčešće definiše globalno za sve neurone u neuronskoj mreži ili barem za svaki sloj mreže. Definisanjem različitih vrednosti praga za svaki neuron pojedinačno, postiže se i različito ponašanje neurona tokom obrade ulaznih informacija. Vrednosti praga se menjaju i tokom procesa učenja prilagođavanjem na optimalne vrednosti koje daju minimalnu grešku na izlazu neurona. Zbog toga se vrednosti praga mogu posmatrati i u vremenskom domenu kao  $b(t)$ .

Različite forme aktivacionih funkcija moguće je upotrebiti u zavisnosti od tipa neuronske mreže koji se koristi, ulaznih i izlaznih podataka koje treba obraditi, tipa trenažnog procesa, itd... Kako je već navedeno u prethodnom potpoglavlju, najčešći tipovi aktivacionih funkcija su bipolarne, linearne i nelinearne. Bipolarne funkcije na svojim izlazima generišu dva moguća stanja ( $\{0, 1\}$  ili  $\{-1, 1\}$ ), dok su kod linearnih funkcija izlazne vrednosti linearno zavisne od

ulaznih. Ipak, za složenije neuronske mreže koje obrađuju kompleksne skupove podataka najčešće se koriste nelinearne aktivacione funkcije. Za njih je karakteristično da su kontinualne i da im je opseg izlaznih vrednosti unutar tačno definisanih granica. Nelinearnost podrazumeva nelinearnu promenu izlaza funkcije u odnosu na ulazne informacije, što omogućava mreži da uradi nelinearno mapiranje na relaciji ulaz-izlaz. Kontinualnost podrazumeva da nema oštih pikova ili nedefinisanih vrednosti funkcije. Navedene karakteristike su direktni rezultat pokušaja da se razvije model koji će imitirati biološki neuron kod koga su izlazi nelinearni, kontinualni i ograničeni. Na slici 1.4 su prikazani neki od najčešće korišćenih tipova aktivacionih funkcija, dok su u tabeli 1.2 date njihove matematičke formulacije.



Slika 1.4 Tipovi aktivacionih funkcija

Tabela 1.2 Matematička formulacija prikazanih aktivacionih funkcija

Prag funkcija	Bipolarna funkcija	Sigmoidalna funkcija	Linearna funkcija
$Y = \begin{cases} 1, & \text{ako } X \geq 0 \\ 0, & \text{ako } X < 0 \end{cases}$	$Y = \begin{cases} +1, & \text{ako } X \geq 0 \\ -1, & \text{ako } X < 0 \end{cases}$	$Y = \frac{1}{1+e^{-X}}$	$Y = X$
Gausova funkcija	Komplement Gausove funkcije	Hiperbolična tangentna funkcija	U delovima linearna funkcija
$Y = e^{-X^2}$	$Y = 1 - e^{-X^2}$	$Y = \frac{1+e^{-X}}{1-e^{-X}}$	$Y = \begin{cases} a & \text{ako } x < c \\ b & \text{ako } x > d \\ a + \frac{(x-c)(b-a)}{(d-c)} & \text{za ostalo} \end{cases}$

Za modeliranje jednostavnijih sistema i procesa može biti dovoljna upotreba aktivacione funkcije tipa prag, bipolarne ili linearne funkcije. Sigmoidalne funkcije se zbog svog izgleda nazivaju i S-funkcijama. Definisane su na opsegu izlaznih vrednosti ( $\{0, 1\}$ ), a nagib krive ove funkcije definiše njenu dinamiku. Promena nagiba može se ostvariti uvođenjem parametra  $T$  u postojeću formulu aktivacione funkcije iz tabele 1.2:

$$y = \frac{1}{1 + e^{\frac{-x}{T}}} \quad (1.6)$$

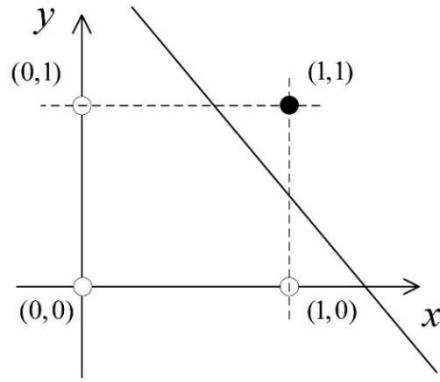
Što je manji parametar  $T$  iz jednačine (1.6) utoliko će karakteristika biti bliža  $X$  osi. Pri dovoljno niskoj vrednosti ovog parametra sigmoidalna funkcija će poprimiti oblik funkcije praga.

Gausova aktivaciona funkcija ima oblik simetričnog zvona i često se naziva standardnom funkcijom za normalnu distribuciju podataka. Opseg izlaznih vrednosti je ( $\{0, 1\}$ ) i najveća osetljivost funkcije je za ulazne vrednosti bliske nuli, dok je skoro neosetljiva pri krajevima – gde ulazi poprimaju velike vrednosti. Ovu funkciju je najbolje koristiti kada je potrebna najveća osetljivost mreže za ulazne signale malih vrednosti. Komplement Gausove funkcije je inverzna Gausova funkcija i obezbeđuje najveće izlazne vrednosti neurona za velike ulazne vrednosti. Koristi se u mrežama kod kojih se želi veća izlazna osetljivost za velike ulazne vrednosti. Na kraju, hiperboličnom tangentnom funkcijom definisan je opseg izlaznih vrednosti ( $\{-1, 1\}$ ). Odlika ove kao i sigmoidalne funkcije je njihova diferencijabilnost.

Kada se aktivacione funkcije koriste u izlaznim neuronima mora se voditi računa o komparaciji željenih i dobijenih izlaznih vrednosti i izvršiti po potrebi skaliranje elemenata. Ukoliko se odabere neka od funkcija koja generiše na izlazu vrednosti iz opsega ( $\{0, 1\}$ ), željeni izlazi se moraju skalirati da odgovaraju izlaznom opsegu aktivacione funkcije, kako bi mogli adekvatno da se uporede.

### 1.3.1.3 Primena perceptrona za rešavanje linearno separabilnih problema

Struktura perceptrona je pogodna za rešavanje linearno separabilnih problema. Linearna separabilnost (odvojivost) predstavlja geometrijsku karakteristiku para skupova informacija (tačaka). Najlakše se može vizuelno predstaviti grafikom u dve dimenzije (xy ravan). Neka je skup svih tačaka podeljen u dva skupa: jedan u okviru koga su tačke bele boje, i drugi u kome su tačke crne. Ova dva skupa su linearно separabilna ukoliko postoji najmanje jedna linija u ravni xy pomoću koje se mogu odvojiti sve bele tačke prvog skupa od svih crnih tačaka drugog skupa. Na slici 1.5 je predstavljen primer linearно separabilnog problema.



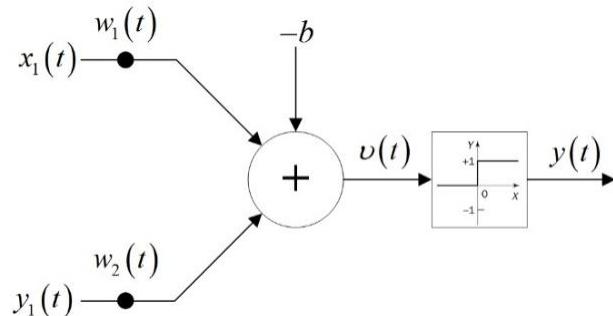
Slika 1.5 Linearna separabilnost logičkog  $I$  kola

Položaj tačaka na slici 1.5 odgovara logičkoj operaciji  $I$ , čija se dva linearно separabilna skupa mogu predstaviti na sledeći način:

$$g(x_1, y_1) = \begin{cases} 1, & x_1 = y_1 = 1 \\ 0, & \text{za ostale vrednosti} \end{cases} \quad (1.7)$$

Kao što se može zaključiti, prvi skup sadrži jednu tačku sa vrednošću 1, dok drugi skup sadrži tri tačke čija je vrednost funkcije jednaka 0. Sa slike 1.5 vidimo da je problem linearно separabilan, odnosno da je dva skupa moguće odvojiti pravom linijom.

U nastavku će biti dat primer projektovanja perceptronu kojim se može izvršiti implementacija logičke funkcije  $ILI$  za dve ulazne promenljive  $x_1$  i  $y_1$ . Željeni perceptron sa dva ulaza i aktivacionom funkcijom tipa prag može se prikazati na sledeći način:



Slika 1.6 Grafički prikaz perceptronu

Na osnovu grafičkog prikaza sa slike 1.6 može se napisati jednačina perceptronu:

$$\begin{aligned} y &= f(w_1x_1 + w_2y_1 - b), \\ g(x_1, y_1) &= f(w_1x_1 + w_2y_1 - b). \end{aligned} \quad (1.8)$$

Na osnovu prethodne jednačine može se formirati prava linija oblika:

$$w_1x_1 + w_2y_1 - b = 0. \quad (1.9)$$

Logička funkcija *ILI* oblika  $g(x_1, y_1)$  može se predstaviti na sledeći način:

$$g(x_1, y_1) = \begin{cases} 0, & x_1 = y_1 = 0 \\ 1, & \text{za ostale vrednosti} \end{cases} \quad (1.10)$$

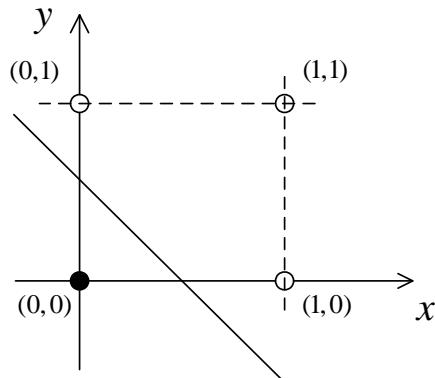
Uzevši u obzir da je iskorišćena aktivaciona funkcija tipa prag za koju važi da je:

- za svako odabранo  $x < 0$  na izlazu  $y = 0$ ,
- za svako odabranو  $x \geq 0$  na izlazu  $y = 1$ ,

može se zaključiti da je funkciju  $g(x_1, y_1) = f(w_1x_1 + w_2y_1 - b)$  moguće predstaviti kroz četiri slučaja:

$$\begin{aligned} g(0,0) &= 0, \quad 0 < b \\ g(0,1) &= 1, \quad w_2 \geq b \\ g(1,0) &= 1, \quad w_1 \geq b \\ g(1,1) &= 1, \quad w_1 + w_2 \geq b. \end{aligned} \quad (1.11)$$

Na osnovu (1.11) se jasno uočavaju 2 skupa tačaka (sa vrednostima 0 i 1) koji se mogu grafički prikazati kao na narednoj slici.



Slika 1.7 Grafički prikaz *ILI* logičke funkcije

Logičko *ILI* kolo može se realizovati i Matlab programom. Težinski koeficijenti, prag osetljivosti i odgovarajući ulazni i izlazni vektori se podešavaju na osnovu dobijenih uslova iz (1.9).

Matlab kod:

```
>> P = [0 0 1 1; 0 1 0 1]; % definisanje vektora ulaza
>> T = [0 1 1 1]; % definisanje vektora izlaza
>> net = newp(P,T); % naredba kojom se realizuje perceptron za zadate ulaze/izlaze
>> net.IW{1,1} = [2 2]; % podešavanje težinskih koeficijenata
>> net.b{1} = -2; % podešavanje vrednosti praga osetljivosti mreže
>> A = sim(net,P) % simulacija rada perceptrona na osnovu ulaznog vektora P
A =
    0     1     1     1 % dobijeni izlazi iz perceptrona
```

```

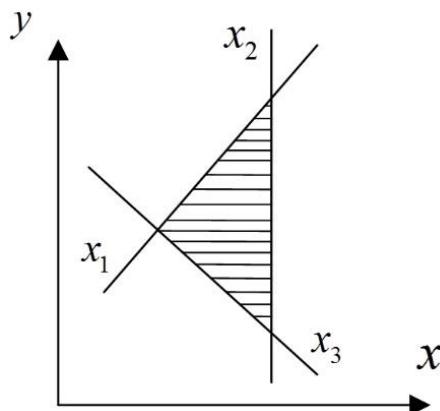
>> c = [0;1];           %formiranje novog ulaznog vektora
>> A = sim(net,c)      %simulacija rada perceptron na osnovu zadatog ulaza
A =
    1                   %dobijeni izlazi na osnovu ulaznog vektora c
>> d = [0;0];           %formiranje novog ulaznog vektora
>> A = sim(net,d)      %simulacija rada perceptron na osnovu zadatih ulaza
A =
    0                   %dobijeni izlazi na osnovu ulaznog vektora d

```

Inicijalizovani perceptron nema funkciju učenja. Da bi neuron kao osnovna procesorska jedinica i neuronska mreža kao celina bili u potpunosti funkcionalni potrebno je uvesti matematički aparat koji omogućava obuku mreže i samoregulaciju težinskih koeficijenata na osnovu zadatih trenažnih podataka. Veštačke neuronske mreže i proces učenja biće obrađeni u okviru narednog poglavlja.

### 1.3.2 Umrežavanje perceptronra i odabir potrebne strukture neuronske mreže

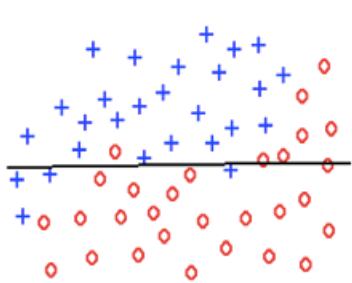
Rešavanje linearne separabilnih problema pomoću perceptronra je već pokazano. Kombinacijom više perceptronra može se ukrstiti veći broj pravih linija kako bi se izvršila separacija složenijih grupa podataka. Primer takve klasifikacije dat je na slici 1.8 gde se problem obrade svodi na formu prepoznavanja podataka koji se nalaze ispod prave linije  $x_1$ , levo od prave linije  $x_2$  i iznad prave linije  $x_3$ . Sintezom više perceptronra formira se struktura koja se naziva neuronskom mrežom. O njoj će biti govora u nastavku poglavlja.



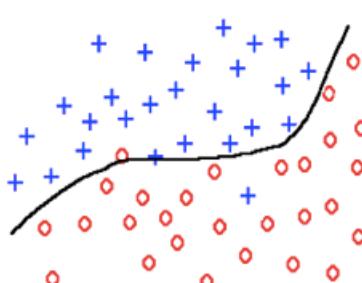
Slika 1.8 Primer klasifikovane oblasti pomoću neuronske mreže

Višeslojna neuronska mreža predstavlja univerzalni aproksimator funkcija. Zapis strukture svake neuronske mreže vrši se u formatu ( $u$ - $s$ - $i$ ), gde je  $u$  broj ulaznih neurona mreže,

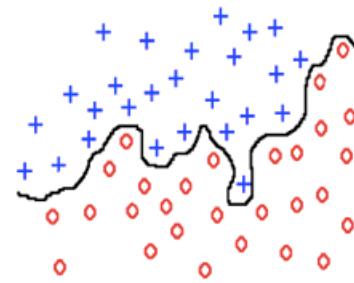
s broj neurona u skrivenom sloju i  $i$  broj neurona u izlaznom sloju. Na primer, neuronska mreža sa 5 neurona u ulaznom sloju, 3 neurona u skrivenom sloju i 4 neurona u izlaznom sloju biće zapisana u obliku: (5-3-4). Najčešći oblik mreža su one sa jednim skrivenim slojem jer su u najvećem broju slučajeva dovoljne za rešavanje većine problema. Dodavanje svakog narednog skrivenog sloja unutar mreže sa sobom donosi veću moć obrade podataka ali i generisanje novih lokalnih minimuma grešaka funkcija u okviru kojih se mreža može zarobiti prilikom procesa učenja. Takođe, povećava se kompleksnost modela, proračunsko vreme potrebno za obradu podataka, cena realizacije... U skladu s tim, uvek je najbolje pokušati rešavanje problema sa jednostavnom strukturu mreže i jednim skrivenim slojem. Ukoliko se empirijski pokaže da neuronska mreža ne pokazuje zadovoljavajuće rezultate onda je opravdano povećati broj skrivenih slojeva. Mreže koje poseduju jednostavnu strukturu sa malim brojem neurona lako će izbeći učenje poremećaja i šumova trening podataka, što olakšava generalizaciju podataka u poređenju sa složenijim mrežama. Strukturu mreže je opravdano povećati kada trenutna mreža ne može da pruži željene performanse i kada vrši lošu generalizaciju podataka (Slika 1.9.1). Na slici 1.9.2 prikazan je primer dobre generalizacije gde je izbegнута појава учења poremećaja i једићних података који се могу сматрати нерепрезентативним. На slici 1.9.3 dat je primer generalizacione sposobnosti složene mreže за коју се не може сматрати да је добра. Таква мрежа је naučila sve тrenažне податке, али је zbog nepravilне generalizације teško примениљива на нове скупове података.



Slika 1.9.1 Slaba generalizacija



Slika 1.9.2 Dobra generalizacija



Slika 1.9.3 Loša generalizacija

Da bi se izbegli rezultati kao na slikama 1.9.1 i 1.9.3 potrebno je upotrebiti jednu od dve mogućnosti za izbor mreže. Prva je kaskadno-korelacioni odabir gde se polazi od jednostavne strukture mreže, testiranjem se utvrđuju performanse i struktura mreže se kroz iteracije usložnjava dok sposobnost mreže za obradom podataka nije na zadovoljavajućem nivou. Druga mogućnost podrazumeva obrnut pristup, polazna tačka je složena mreža sa dostignutim

željenim performansama. Kroz test iteracije se dalje oslabljuju ili eliminišu pojedinačne sinaptičke težine mreže na selektivan način: analiziraju se njihove vrednosti i eliminišu one čiji je značaj za reprodukovanje izlaza zanemarljiv. Cilj je uprošćavati strukturu mreže sve dok je moguće zadržati i željene performanse.

Pored predstavljene empirijske procedure za odabir mreže moguće je uvesti i kriterijum za odabir kompleksnosti modela. Cilj učenja je da se pronađe težinski vektor koji minimizuje ukupan rizik uprošćavanja mreže:

$$R(\omega) = J(\omega) + \lambda J_c(\omega), \quad (1.12)$$

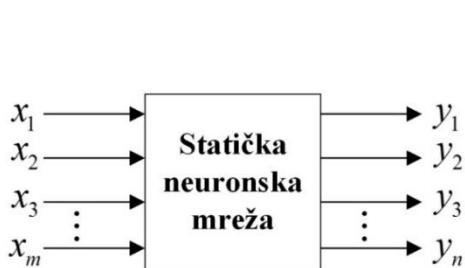
gde je  $J(\omega)$  mera performansi,  $J_c(\omega)$  predstavlja vrednost kazne usled kompleksnosti mreže,  $\lambda$  je regulacioni parametar koji predstavlja relativnu važnost parametra  $J_c(\omega)$  u odnosu na meru performansi. Parametar  $J_c(\omega)$  zavisi od složenosti mreže, tj. njegova vrednost zavisi od evaluacije svih sinaptičkih težina mreže. Kada je regulacioni parametar  $\lambda = 0$ , *backpropagation* proces učenja biće bez ograničenja, odnosno buduća struktura mreže biće kompletno određena isključivo iz trening primera. Kada  $\lambda \rightarrow \infty$ , mreža je u potpunosti određena ograničenjem  $J_c(\omega)$ . To znači da su trening podaci nepouzdani i nedovoljni za obuku mreže i generisanje željenih rezultata. Procedura ažuriranja težina u zavisnosti od parametra kazne definiše se kao kvadratna norma vektora težina:

$$J_c(\omega) = \|\omega\|^2 = \sum \omega_i^2. \quad (1.13)$$

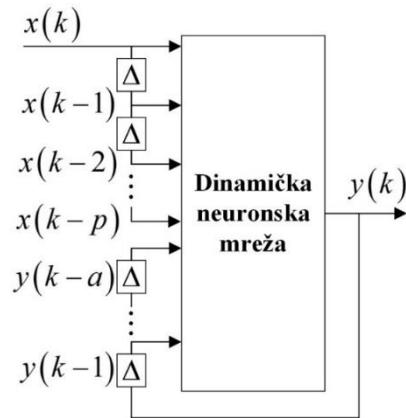
Ovaj parametar regulacije kompleksnosti utiče na to da pojedine sinaptičke težine uzmu vrednosti blizu nule. Takve težine se smatraju viškom i mogu se eliminisati, čime se struktura mreže uprošćava.

### 1.3.3 Modeli veštačkih neuronskih mreža

Osnovna podela neuronskih mreža je na statičke i dinamičke. Za upravljanje većinom nelinearnih procesa uglavnom se koriste višeslojne statičke neuronske mreže. Zadatak ovakve mreže (Slika 1.10) je da nauči preslikavanje skupa zadatih ulaza ( $x_1, x_2, \dots, x_m$ ) na skup željenih izlaza ( $y_1, y_2, \dots, y_n$ ).



Slika 1.10 Model statičke neuronske mreže



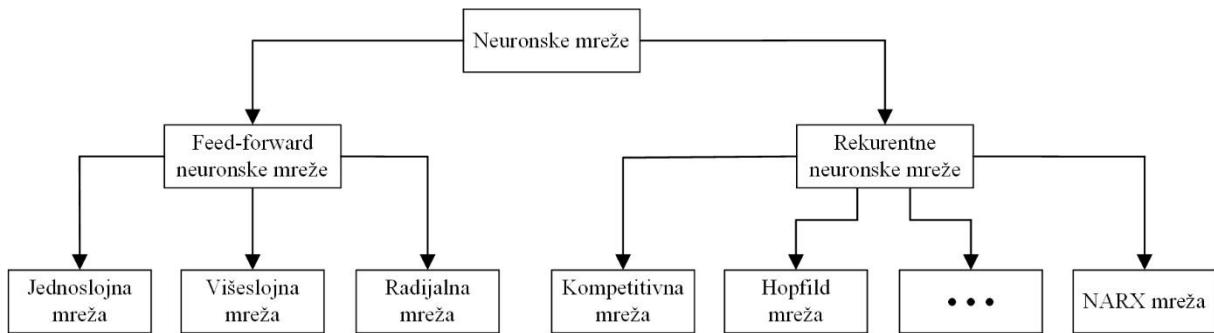
Slika 1.11 Model dinamičke neuronske mreže

Glavna karakteristika statičkih neuronskih mreža je da prilikom formiranja veza između neurona ne formiraju povratne (rekurentne) veze, što ih čini strukturno stabilnim. Vremenski su nezavisne što znači da ne zavise od trenutnog stanja u kome se sistem nalazi već generiše sekvencu izlaza isključivo na osnovu trenutnih ulaza koji su dovedeni na mrežu. Statičke mreže se mogu realizovati mrežama koje vrše propagiranje informacije unapred (*feedforward* mreže).

Dinamičkim neuronskim mrežama smatraju se višeslojne mreže koje poseduju dinamičke elemente čija je funkcija da obezbede pamćenje ulaznih i izlaznih informacija. Preslikavanje ulaza na izlaze dinamičkih mreža zavisi od vremenskog faktora, odnosno od stanja u kom se mreža trenutno nalazi. Sadrže povratne veze u modelu čime se omogućava neuronskoj mreži da ima sposobnost memorisanja, odnosno, pamćenja stanja. Takvoj mreži se pored standardnih ulaza u mrežu dovode i ulazi koji predstavljaju prethodne vrednosti ulaza i izlaza sistema (Slika 1.11).

### 1.3.3.1 Topologije neuronskih mreža

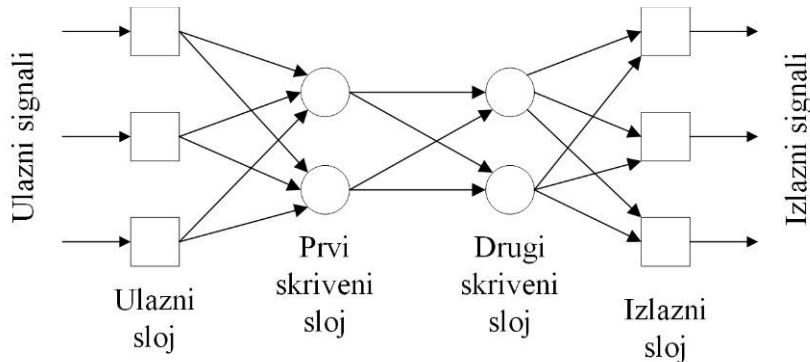
U pogledu načina propagiranja informacija, neuronske mreže se dele u dve kategorije: sa propagiranjem informacija unapred (*feedforward* mreže), i sa povratnom spregom (rekurentne). *Feedforward* mreže se smatraju statičkim mrežama, odnosno, generišu skup izlaznih informacija na osnovu ulazne sekvence podataka. Na drugoj strani, rekurentne mreže su dinamički sistemi sa karakteristikom memorisanja podataka. Neki od osnovnih tipova *feedforward* i rekurentnih mreža prikazani su na slici 1.12. Treba imati na umu da različite arhitekture mreža obično zahtevaju i različite tipove trenažnog procesa koje je potrebno odabratи da bi se na optimalan način izvršila obuka mreže.



Slika 1.12 Tipovi neuronskih mreža

### 1.3.3.2 Arhitektura standardne višeslojne neuronske mreže

Višeslojna neuronska mreža se u svom osnovnom obliku sastoji od ulaznog sloja sa izvornim neuronima, bar jednim skrivenim slojem sa procesnim neuronima i izlaznog sloja sa takođe procesnim neuronima. Procesni neuroni su oni koji obrađuju ulazne informacije i formiraju izlazne vrednosti na osnovu implementiranih aktivacionih funkcija (Slika 1.2), dok izvorni neuroni ulaznog sloja imaju samo mogućnost propagiranja informacija kroz njih. Ulazni signali dovedeni na ulazne neurone mreže se propagiraju unapred, sloj po sloj. Primer višeslojne mreže sa tri neurona u ulaznom sloju, po dva neurona u prvom i drugom skrivenom sloju i tri neurona u izlaznom sloju, prikazan je na slici 1.13.



Slika 1.13 Primer topologije višeslojne neuronske mreže

Svaki sloj neuronske mreže ima svoju tačno definisana funkciju u procesu obrade informacija. Ulazni sloj prima ulazne signale iz spoljašnjeg sveta i distribuira ih do svih neurona u skrivenom sloju. Skriveni sloj se naziva tako iz razloga što neuroni u ovom sloju ne mogu biti nadgledani kroz ulazno/izlazna stanja neuronske mreže. Ne postoji način da se utvrdi koji bi bili željeni izlazi skrivenog sloja. Drugim rečima, željene izlaze skrivenog sloja određuje sam

skriveni sloj. Neuroni ovog sloja procesiraju ulazne informacije i daju na izlazima odgovarajuće izlazne signale koje prihvataju neuroni izlaznog sloja. Neuronska mreža sa jednim skrivenim slojem je dovoljna za predstavljanje bilo koje kontinualne funkcije, dok sa dva skrivena sloja mogu da se aproksimiraju i diskontinualne funkcije. Neuronska mreža se može formirati i sa više od dva skrivena sloja, ali najveći broj aplikacija pokazuje odlične rezultate već sa samo jednim skrivenim slojem. Implementacija dodatnih slojeva nije garant povećanja performansi neuronske mreže, a bitno utiče na povećanje proračunskog vremena. Duže vreme proračuna se ogleda kroz duže vreme potrebno za obuku i rad neuronske mreže. Dalje, podrazumeva se da složenija struktura sa većim brojem procesnih jedinica (neurona), zahteva i veću računarsku memoriju i brži procesor kako bi se postigla optimalna brzina rada mreže.

## **1.4 Algoritmi i parametri učenja perceptron. Treniranje neuronskih mreža. *Backpropagation* model neuronske mreže**

### **1.4.1 Algoritmi učenja perceptron**

#### **1.4.1.1 Perceptron pravilo učenja na principu učitelj-učenik**

Zadatak svakog procesa učenja perceptron je podesiti težinske koeficijente ( $\omega_1, \omega_2, \dots, \omega_n$ ) i aktivacioni prag ( $b$ ) tako da za dovedene ulaze ovi parametri generišu željene izlazne vrednosti. Tokom procesa učenja perceptron se može smatrati učenikom koji odgovara na postavljena pitanja ( $x_1, x_2, \dots, x_n$ ), gde je svako  $x_i$  jedno pitanje. Odgovori učenika  $S$  porede se sa odgovorima na ista pitanja koje daje učitelj  $U$ . Odgovori učitelja i učenika mogu imati dve vrednosti (0 ili 1), gde 0 predstavlja odgovor NE na postavljeno pitanje, a 1 odgovor DA na postavljeno pitanje. Generisanje odgovora zavisi od aktivacionog praga i konačnog ulaza u perceptron koji se formira u zavisnosti od trenutnih vrednosti težinskih koeficijenata i ulaznih signala ( $x_1, x_2, \dots, x_n$ ). Odgovor (izlaz) perceptron se formira na sledeći način:

- ako je  $ulaz > b$  generiše se na izlazu odgovor učenika :  $S = 1$
- ako je  $ulaz < b$  generiše se na izlazu odgovor učenika :  $S = 0$ .

Perceptron pravilo učenja podrazumeva promenu parametara perceptrona kada on napravi grešku pri odgovaranju, odnosno kada se ne poklapaju odgovori učenika i učitelja:  $S \neq U$ . Celokupni proces učenja podrazumeva sledeće:

1. Projektovati perceptron sa odgovarajućim brojem ulaza i jednim izlazom. Odabratи почетне vrednosti težinskih koeficijenata i aktivacionih pragova.
2. Odabratи pitanja (ulazne vrednosti) koja se dovode na ulaze perceptrona  $(x_1, x_2, \dots, x_n)$ .
3. Generisati odgovore perceptrona na osnovu postavljenih pitanja.
4. Uporediti odgovore perceptrona (učenika)  $S(x_1, x_2, \dots, x_n)$  sa željenim odgovorima (odgovorima učitelja)  $U(x_1, x_2, \dots, x_n)$ :
  - a. ako je  $S = U$  nije potrebna obuka pošto je perceptron dao tačne odgovore
  - b. ako je  $S = 1$  i  $U = 0$ , izvršiti promene težinskih koeficijenata i aktivacionih pragova:  $\omega_i \rightarrow \omega_i - x_i$  i  $b \rightarrow b + 1$
  - c. ako je  $S = 0$ ,  $U = 1$  izvršiti promene težinskih koeficijenata i aktivacionih pragova:  $\omega_i \rightarrow \omega_i + x_i$  i  $b \rightarrow b - 1$ .

Kada perceptron generiše pogrešan rezultat na izlazu  $S = 1$ , to implicira da je  $ulaz > b$  umesto željene vrednosti  $ulaz < b$ . Zbog toga se prave modifikacije parametara tako da vrednost ulaza kao prezentacija pojedinačnog pitanja bude redukovana težinskim koeficijentom i aktivacionim pragom. To se postiže smanjenjem vrednosti težine čime se direktno utiče na redukciju ulazne vrednosti, dok povećanje praga  $b$  povećava i potrebnu ulaznu vrednost za generisanje izlaza  $S = 1$ . Time se povećava verovatnoća generisanja rezultata  $S = 0$  za to pitanje, što i jeste cilj učenja. Ukoliko, pak, perceptron greškom prikaže rezultat  $S = 0$ , to implicira da je  $ulaz < b$  umesto željene vrednosti  $ulaz > b$ . Ovakva greška znači da je vrednost ulaza manja od aktivacionog praga, i, da bi perceptron generisao željenu vrednost na izlazu, potrebno je povećati težinske koeficijente i time multiplikovati ulaznu vrednost. Takođe, smanjuje se vrednost aktivacionog praga, čime se omogućava da se za manju ulaznu vrednost generiše na izlazu 1. Nakon pojedinačne iteracije procesa učenja ponavljaju se koraci 3 i 4 sve dok se ne poklope odgovori učenika i učitelja, čime se trenažni proces smatra uspešnim.

U nastavku je prikazan primer realizacije perceptrona u Matlab-u. Perceptron iz primera se sastoji od 2 ulaza i jednog izlaza.

```
>> x = [0 1 0 1; 0 0 1 1]; % definisanje ulaznih vrednosti perceptrona - pitanja
>> U = [0 1 1 1]; % definisanje izlaza – odgovora učitelja
>> net = newp(x,U); % formiranje novog perceptrona
>> net.IW{1,1} = [5 1]; % dodeljivanje početnih vrednosti težinskim koeficijentima
>> net.b{1} = [-5]; % dodeljivanje početne vrednosti aktivacionom pragu
```

```

>> net = train(net,x,U);      % treniranje perceptrona
>> a = sim(net,x)           % simulacija rada perceptrona nakon treninga
a =
0 1 1 1                     % rezultati treniranog perceptrona (odgovori učenika - S)
>> net.IW{1,1}
ans =
5 3                         % težinski koeficijenti nakon treninga
>> net.b{1}
ans =
-3                          % aktivacioni prag nakon treninga

```

#### 1.4.1.2 Roseblatt-ovo pravilo učenja perceptrona

Još jedan popularan način obuke perceptrona je Roseblatt-ovo pravilo učenja. Algoritam modifikovanja parametara perceptrona može se predstaviti u matričnom obliku:

$$\begin{aligned} W(i+1) &= W(i) + e_k (p_k)^T, \\ b(i+1) &= b(i) + e_k, \end{aligned} \quad (1.14)$$

gde su  $W(i)$  i  $b(i)$  vektori težinskih koeficijenata i aktivacionih pragova u  $i$ -toj iteraciji,  $e_k$  predstavlja grešku na izlazu perceptrona,  $p_k$  ulazni skup podataka, a  $W(i+1)$  i  $b(i+1)$  su vrednosti parametara perceptrona za narednu iteraciju  $(i+1)$ . Greška  $e_k$  formira se kao razlika željene i dobijene izlazne vrednosti:

$$e_k = t_k - y_k. \quad (1.15)$$

Algoritam Roseblatt-ovog pravila učenja može se predstaviti kroz 6 koraka:

1. Definisati početne vrednosti težinskih koeficijenata  $\omega_i$  i aktivacionog praga  $b$  perceptrona.
2. Dovesti na ulaz perceptrona ulazni vektor  $p_k$ .
3. Izračunati izlaznu vrednost perceptrona:  $y = f(Wp + b)$ .
4. Odrediti grešku:  $e_k = t_k - y_k$ .
5. Ako je  $e_k = 0$ , perceptron je naučio zadati ulazni skup podataka i na ulaze se mogu dovesti naredni podaci bez modifikacija parametara perceptrona.
6. Ukoliko je  $e_k \neq 0$ , izvršava se rekalkulacija parametara perceptrona iz (1.14), pa se nakon toga mogu obraditi novi podaci dovedeni na ulaze.

7. Nakon procesiranja svih ulaznih podataka, dovođenje skupova podataka počinje iz početka, sve dok greška  $e_k$  za sve ulazne vrednosti ne bude jednaka nuli.

U nastavku će biti dat primer funkcionisanja Roseblatt-ovog pravila učenja na sledećem skupu ulazno-izlaznih podataka perceptronra:

$$\left( p_1 = \begin{Bmatrix} 2 \\ 4 \end{Bmatrix}, t_1 = 1 \right), \left( p_2 = \begin{Bmatrix} -2 \\ 4 \end{Bmatrix}, t_2 = 0 \right), \left( p_3 = \begin{Bmatrix} 0 \\ -2 \end{Bmatrix}, t_3 = 0 \right).$$

Na osnovu ulaznih vektora zaključuje se da perceptron poseduje 2 ulaza i jedan izlaz. Potrebno je na početku odabrati startne vrednosti težinskih koeficijenata i praga funkcije. Neka su to sledeće vrednosti  $\omega_1(1) = 1$ ,  $\omega_2(1) = -1$ ,  $b(1) = 1$ . Na ulaz perceptronra dovodimo vektor  $p_1$ . Izlaz perceptronra računa se kao:

$$\begin{aligned} y_1 &= f(\omega_1(1)p_{11} + \omega_2(1)p_{12} + b(1)), \\ y_1 &= f(1 \cdot 2 - 1 \cdot 4 + 1) = f(-1) = 0, \end{aligned} \quad (1.16)$$

gde  $y_1$  predstavlja generisani izlaz perceptronra na osnovu koga se određuje greška u prvoj iteraciji:

$$e_1 = t_1 - y_1 = 1. \quad (1.17)$$

Greška je različita od 0 pa je potrebno modifikovati parametre perceptronra u skladu s Roseblatt-ovim pravilom podešavanja:

$$\begin{aligned} \omega_1(2) &= \omega_1(1) + e_1 p_{11} = 1 + 1 \cdot 2 = 3, \\ \omega_2(2) &= \omega_2(1) + e_1 p_{12} = -1 + 1 \cdot 4 = 3, \\ b(2) &= b(1) + e_1 = 1 + 1 = 2. \end{aligned} \quad (1.18)$$

Modifikovani parametri će biti korišćeni u drugoj iteraciji kada se na ulaze perceptronra dovodi skup podataka  $p_2$ :

$$\begin{aligned} y_2 &= f(\omega_1(2)p_{21} + \omega_2(2)p_{22} + b(2)), \\ y_2 &= f(-3 \cdot 2 + 3 \cdot 4 + 2) = f(8) = 1. \end{aligned} \quad (1.19)$$

Ponovo se određuje greška nakon druge iteracije i poredi dobijeni rezultat  $y_2$  sa željenim rezultatom  $t_2$ :

$$e_2 = t_2 - y_2 = 0 - 1 = -1. \quad (1.20)$$

Greška i dalje postoji tako da se određuju nove vrednosti parametara perceptronra:

$$\begin{aligned}\omega_1(3) &= \omega_1(2) + e_2 p_{21} = 3 + 1 \cdot 2 = 5, \\ \omega_2(3) &= \omega_2(2) + e_2 p_{22} = 3 - 1 \cdot 4 = -1, \\ b(3) &= b(2) + e_2 = 2 - 1 = 1.\end{aligned}\quad (1.21)$$

Za skup podataka  $p_3, t_3$  računa se izlazna vrednost kao:

$$\begin{aligned}y_3 &= f(\omega_1(3)p_{31} + \omega_2(3)p_{32} + b(3)), \\ y_3 &= f(5 \cdot 0 + 1 \cdot 2 + 1) = f(3) = 1.\end{aligned}\quad (1.22)$$

Nova greška ima vrednost:

$$e_3 = t_3 - y_3 = 0 - 1 = -1. \quad (1.23)$$

Nakon sekvencijalnog unosa svih skupova podataka vidimo da perceptron nije dobro obučen, tako da je potrebno nastaviti trenažni proces i krenuti sa unosom ulaznih skupova podataka iz početka:

$$\begin{aligned}\omega_1(4) &= \omega_1(3) + e_3 p_{31} = 5 - 1 \cdot 0 = 5, \\ \omega_2(4) &= \omega_2(3) + e_3 p_{32} = -1 + 1 \cdot 2 = 1, \\ b(4) &= b(3) + e_3 = 1 - 1 = 0,\end{aligned}\quad (1.24)$$

$$y_1 = f(\omega_1(4)p_{11} + \omega_2(4)p_{12} + b(4)) = f(5 \cdot 2 + 1 \cdot 4 + 0) = f(14) = 1, \quad (1.25)$$

$$e_1 = t_1 - y_1 = 0. \quad (1.26)$$

Na osnovu poslednje provere greške vidimo da su koeficijenti perceptrona dobro podešeni za generisanje prvog skupa ulazno-izlaznih podataka. Na osnovu toga ne vršimo rekalkulaciju parametara, već iste vrednosti iz zadnje iteracije koristimo i u narednoj:

$$y_2 = f(\omega_1(4)p_{21} + \omega_2(4)p_{22} + b(4)) = f(-5 \cdot 2 + 1 \cdot 4 + 0) = f(-6) = 0, \quad (1.27)$$

$$e_2 = t_2 - y_2 = 0. \quad (1.28)$$

Ni za drugi skup podataka ne postoji greška, tako da iste parametre prenosimo i za testiranje trećeg skupa podataka:

$$y_3 = f(\omega_1(4)p_{31} + \omega_2(4)p_{32} + b(4)) = f(5 \cdot 0 - 1 \cdot 2 + 0) = f(-2) = 0. \quad (1.29)$$

Greška je:

$$e_3 = t_3 - y_3 = 0. \quad (1.30)$$

Može se zaključiti da je greška za sve skupove podataka jednaka nuli. Na osnovu toga se završava trenažni proces i za konačne vrednosti parametara perceptrona uzimaju se vrednosti:

$$\omega_1(4) = \omega_1 = 5, \omega_2(4) = \omega_2 = 1, b(4) = b = 0. \quad (1.31)$$

#### **1.4.1.3 Učenje neuronskih mreža**

Apstraktno gledano, neuronska mreža se može predstaviti crnom kutijom koja za zadati skup ulaznih podataka generiše odgovarajuće izlazne vrednosti. Glavna karakteristika neuronskih mreža je da generisanje željenih izlaza ostvaruju učenjem i trenažnim procesom koji se odvija kroz veći broj iteracija. Cilj iterativnog treninga je unapređenje performansi kroz učenje. Da bi bilo efikasno, učenje neuronske mreže mora biti bazirano na tri karakteristike podataka koje obrađuje: kapacitetu, kompleksnosti podataka, i kompleksnosti obrade podataka. Kapacitet podrazumeva količinu podataka koja se može obraditi pomoću mreže i na osnovu količine podataka mogu se definisati funkcionalnosti mreže. Kompleksnost podataka određuje tip trening podataka koji je potreban mreži da bi bila zagarantovana ispravna generalizacija nakon učenja. Kompleksnost obrade podataka odnosi se na vreme potrebno algoritmu učenja da estimira rešenje iz trening podataka. Veliki broj postojećih algoritama učenja zahteva veliku kompleksnost obrade podataka. U skladu s tim, aktivna oblast savremenih istraživanja u oblasti neuronskih mreža je upravo projektovanje efikasnih algoritama učenja. Proces učenja može se uopšteno predstaviti kroz sledeće korake:

1. Neuronska mreža se stimuliše informacijama iz spoljašnje sredine – ulaznim podacima
2. Neuronska mreža prolazi kroz proces promena slobodnih parametara kao rezultat ove stimulacije – proces učenja
3. Neuronska mreža se ponovo stimuliše ulaznim podacima na koje reaguje na novi način usled promena vrednosti slobodnih parametara.

Važna sposobnost neuronske mreže je da nakon trenažnog procesa identificuje klasu problema i izvrši pravilnu generalizaciju novih podataka dovedenih na treniranu mrežu. Učenje mreže i njena adaptacija na spoljašnju sredinu i nove informacije izvršava se na neki od sledećih načina:

- razvojem novih konekcija među neuronima u okviru postojeće mreže
- brisanjem postojećih međuneuronskih konekcija
- promenom vrednosti težinskih koeficijenata
- promenom vrednosti postojećih aktivacionih pragova pojedinačnih neurona
- promenom tipa aktivacionih funkcija u mreži
- dodavanjem novih neurona u strukturu mreže
- brisanjem postojećih neurona iz strukture mreže.

Od navedenih mogućnosti za modifikaciju mreže najviše se koristi metoda pri kojoj se vrši promena vrednosti težinskih koeficijenata tokom procesa treninga. Brisanje međuneuronskih konekcija može se realizovati takođe preko težinskih koeficijenata kada njihova vrednost postane bliska ili jednaka 0. Tada se propagiranje informacija kroz takve veze sprečava i samim tim njihovo postojanje nije od značaja za mrežu – može se zanemariti. Na sličan način se razvoj novih konekcija ostvaruje u suprotnom smeru: veze sa težinama bliskim 0 se razvijaju dodeljivanjem vrednosti različitih od 0. Modifikacija aktivacionih pragova se najlakše radi kada se njihova vrednost implementira na način koji odgovara težinskim koeficijentima. Takvi aktivacioni pragovi se tokom procesa učenja mogu ažurirati na isti način kao i klasični težinski koeficijenti. Mogućnost promene tipa aktivacionih funkcija neurona nije preporučljiva tokom procesa učenja pošto suštinski menja odziv neuronske mreže. Takođe, menjanje funkcija nije biološki inspirisano, nije intuitivno i preporučuje se u slučajevima kada neuronska mreža nakon trenažnih procesa ne može dostignuti željene rezultate. Brisanje neurona iz strukture neuronske mreže može optimizovati topologiju mreže ali i smanjiti njene procesorske moći. U skladu s tim treba biti pažljiv sa promenom strukture mreže i, kao u slučaju s aktivacionim funkcijama, vršiti kvantitativnu promenu broja neurona tek kada postojeća ne može dati bolje rezultate.

Prva podela algoritama učenja se može napraviti na *offline* i *online* tipove učenja. *Offline* učenje podrazumeva dovođenje celog skupa trening podataka na mrežu, generisanje izlaza, računanje ukupne greške i nakon toga menjanje težinskih koeficijenata mreže. *Offline* trening procedure nazivaju se i serijskim treninzima pošto se serija rezultata ispravlja odjednom. Takav trenažni korak gde se serijski vrše ažuriranja težinskih koeficijenata naziva se epohom. Za razliku od *offline* učenja, *online* učenje funkcioniše tako što se težine menjaju nakon svake sekvence podataka dovedenih na mrežu u jednom trenutku.

Svaki algoritam učenja je zasnovan na obradi trening podataka. U najvećem broju slučajeva trening podaci se sastoje od ulaznog vektora  $p$  sa definisanim  $n$  elemenata:  $p_1, p_2, \dots, p_n$ . Takođe, dovođenjem ulaznih trening podataka u mrežu generišu se izlazi  $y$  koji se mogu porebiti sa željenim izlaznim vrednostima  $t$ . Željeni izlazi  $t$  se analogno ulaznom vektoru mogu predstaviti u obliku:  $t_1, t_2, \dots, t_n$ . Ukupan skup trening podataka je  $P$  i sastoji se od konačnog broja ulazno-izlaznih trening parova  $(p, t)$ .

Na osnovu generisanih vrednosti na izlazu mreže (za odgovarajuće ulazne podatke) može se formirati vektor greške koji predstavlja razliku željenih izlaznih vrednosti  $t$  i stvarno dobijenih izlaznih vrednosti  $y$ :

$$E_p = \begin{pmatrix} t_1 - y_1 \\ t_2 - y_2 \\ \dots \\ t_n - y_n \end{pmatrix}. \quad (1.32)$$

Cilj treninga je izjednačavanje željenih izlaznih vrednosti  $t$  sa realno dobijenim vrednostima  $y$ , uz što manje odstupanje. To dozvoljeno odstupanje se zadaje u obliku vrednosti greške koja se može tolerisati.

U prethodnom poglavlju su dati primeri loše generalizacije usled nedovoljno dobrog odabira strukture neuronske mreže. Do loše generalizacije se može doći i neadekvatnim odabirom trening podataka. Nakon obuke neuronske mreže važno je proveriti da li je mreža memorisala isključivo trening podatke ili će i za nepoznate podatke generisati dobre rezultate, što i jeste zadatak dobro obučene mreže. Ipak, dešava se da je greška dobijena na trenažnim podacima mala ali da za nove podatke, sa kojima se mreža nije susretala, greška bude neprihvatljivo velika. Rešenje za ovaj problem je deoba trening podataka u dve grupe: jednu sa podacima za treniranje mreže i jednu koja sadrži podatke za verifikaciju rada mreže na nepoznatom uzorku. U praksi se najčešće 70% podataka koristi kao trening skup a 30% nasumice odabranih podataka za verifikaciju rada mreže. Trening se u potpunosti može smatrati uspešnim kada mreža pruži dobre rezultate za oba skupa podataka.

Najčešće nije dovoljno samo izračunati brojnu vrednost greške za utvrđivanje performansi mreže. Poželjno je pratiti i progres same greške i njenu promenu tokom učenja. Na taj način se mogu doneti prave odluke o daljem razvoju mreže, ubrzati proces učenja i smanjiti proračunsko vreme računara. U tu svrhu koristi se kriva učenja koja pokazuje progres greške definisane na jedan od više načina koji će biti predstavljeni. Motivacija u realizaciji krive je ta što se grafički veoma jednostavno može pokazati u kojoj meri mreža napreduje sa učenjem.

Jedan način za računanje jedinične greške  $Err_p$  baziran je na pojedinačnom trening uzorku, odnosno određuje se *online*:

$$Err_p = \frac{1}{2} \sum_{i \in I} (t_i - y_i)^2, \quad (1.33)$$

gde je  $i$  i-ti neuron od ukupno  $I$  izlaznih neurona mreže. Drugi način za računanje greške bio bi korišćenjem Euklidskog rastojanja između dva vektora,  $t$  i  $y$ :

$$Err_p = \sqrt{\sum_{i \in I} (t_i - y_i)^2}. \quad (1.34)$$

Ipak, najkorišćenija metoda je metoda srednjekvadratne greške:

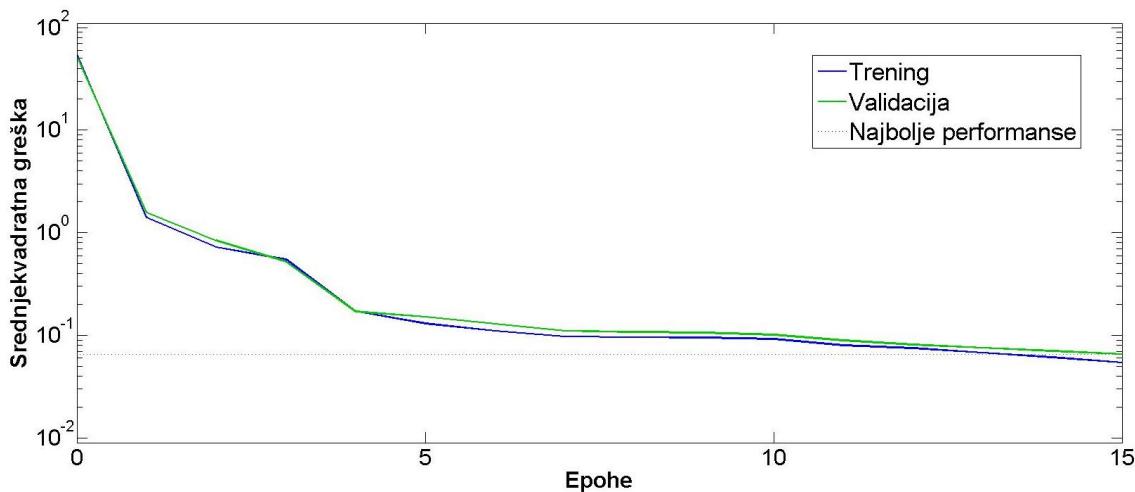
$$Err_p = \sqrt{\frac{\sum_{i \in I} (t_i - y_i)^2}{|I|}}. \quad (1.35)$$

Ukupna greška jedne trening epohe bazirana je na svim trenažnim primerima dovedenim na mrežu, generiše se *offline*, i može se predstaviti kao:

$$Err = \sum_{p \in P} Err_p. \quad (1.36)$$

Optimalna kriva učenja liči na negativnu eksponencijalnu funkciju (Slika 1.14). Mrežu koja ima dobru sposobnost učenja datih podataka karakteriše kriva učenja koja će progresivno opadati do neke minimalne vrednosti kada će uči u ustaljeno stanje. Tada je lako zaključiti da je mreža dosegla limit učenja i da se ne mogu od nje očekivati značajnija unapređenja rezultata.

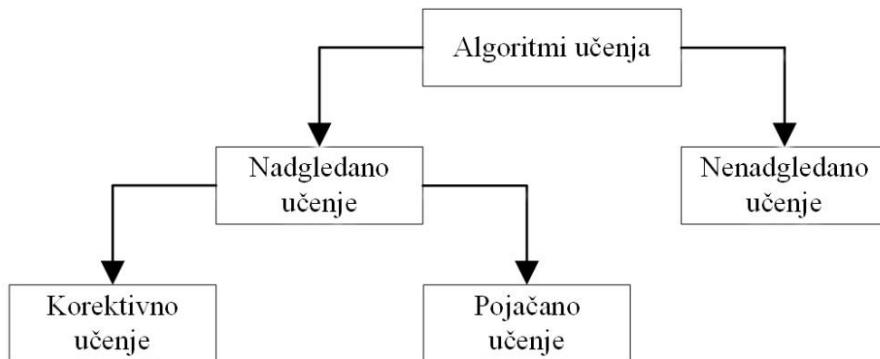
Trening se završava kada definisana dozvoljena greška mreže bude ostvarena ili kada se završi predviđeni broj iteracija učenja mreže. Provera rezultata se vrši testiranjem obučene mreže nad sekvencom novih podataka. Kada se u nekoliko iteracija postignu približni rezultati to je znak da je dostignut maksimum obuke te mreže. Na slici 1.14 dat je prikaz dve krive učenja, jedna koja prikazuje rezultate učenja trening podataka i druga koja prati procesiranje validacionih podataka.



Slika 1.14 Primer trening i validacione krive učenja

Generalno, očekuje se da rezultati validacione krive budu nešto lošiji i sa većim oscilacijama u odnosu na trening krivu. Ali ukoliko je generalizacija urađena dobro tokom procesa treninga obe krive će u ustaljenom stanju imati približno iste vrednosti (kao što je slučaj sa rezultatima na slici 1.14). Kriva učenja takođe može signalizirati lošu generalizaciju i loše

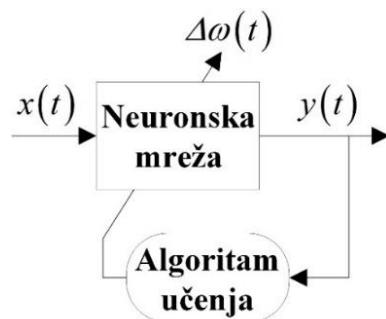
memorisanje trening podataka od strane mreže. To se manifestuje naglim porastom greške krive učenja validacionih podataka dok kriva učenja trening podataka zadržava trend opadanja greške. Tada je potrebno vršiti modifikacije unutar postojeće strukture mreže kako je već opisano na početku ovog poglavlja. Na slici 1.15 nalazi se grafički prikaz osnovne podele tipova učenja neuronske mreže. O svakom od njih biće više reči u nastavku.



Slika 1.15. Osnovna podela algoritama učenja

### Nenadgledano učenje neuronske mreže

Nenadgledano učenje (Slika 1.16) podrazumeva obradu podataka bez pomoći spoljašnjeg faktora (učitelja) pri njihovom procesiranju i procesu učenja. To znači da sistem ni u jednom trenutku nema željene izlazne vrednosti na osnovu kojih bi mogao da vrši podešavanje svojih parametara.



Slika 1.16 Algoritam nenadgledanog učenja

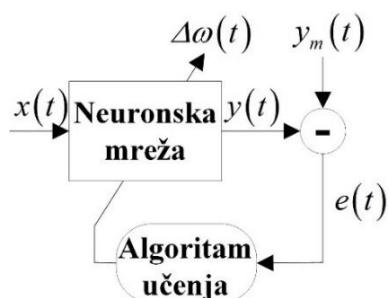
Drugi naziv za nenadgledano učenje je kompetitivno učenje. Naziv je dobilo zbog karakteristika ovakvog trenažnog algoritma da neuron koji dobija najveću ulaznu vrednost postaje pobednik, favorizuje se i time usporava (koči) ostale neurone (neurone gubitnike). To znači da pobednički neuroni utiču u najvećoj meri na formiranje izlaznih vrednosti mreže. Snage konekcija neurona koji pobuđuju neuron pobednika se povećavaju, dok se neuroni koji

ne šalju signale pobedniku usporavaju i njihova snaga opada. U tom smislu, favorizovani neuroni postaju još osetljiviji na ulazne podatke. Tokom vremena će se ovom procedurom različiti neuroni specijalizovati za različite podatke. Mreža identificuje podatke sa sličnim karakteristikama i klasifikuje ih po naučenim kategorijama.

Nenadgledano učenje po svojim karakteristikama ima najviše sličnosti sa učenjem biološke neuronske mreže. Ovakav tip algoritma učenja poseduju samoorganizirajuće mreže. One imaju sposobnost mnogo bržeg učenja nego klasične *backpropagation* mreže i vrlo su efikasne pri rešavanju problema u realnom vremenu. Ipak, nemogućnost utvrđivanja greške učenja tokom treninga može da dovede i do loše generalizacije koja ne može da se popravi reakcijom korisnika.

### **Nadgledano (korektivno) učenje neuronskih mreža**

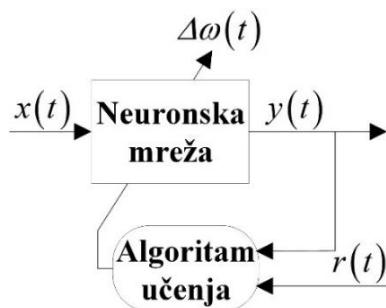
Generalizovano nadgledano učenje (Slika 1.17) predstavlja tip korektivnog učenja. Za razliku od nenadgledanog, ono zahteva ne samo ulazne već i željene izlazne trening podatke. Algoritam omogućava mreži da direktno poredi stvarno dobijene i željene izlazne vrednosti, formira grešku koju propagira unazad kroz mrežu i automatski menja težinske koeficijente na osnovu napravljene greške. Cilj je modifikovati težine tako da mreža generiše željene izlaze za dovedene ulaze. Takođe, zadatak mreže je da bude sposobna za dobru generalizaciju podataka, odnosno da pravilno obradi i nove podatke koji nisu bili obuhvaćeni treningom. Algoritam učenja nije zasnovan na biološkom principu učenja, ali je efikasan i veoma praktičan za upotrebu. Naziva se i učenjem sa učiteljem pošto algoritam ima pristup tačnim odgovorima za skup ulaznih podataka dovedenih na mrežu. Detaljan prikaz principa nadgledanog učenja biće predstavljen u narednom poglavlju u okviru obrade *backpropagation* tipa treninga.



Slika 1.17 Algoritam nadgledanog učenja

## Pojačano učenje neuronskih mreža

Jedna forma nadgledanog učenja je algoritam pojačanog učenja neuronske mreže (Slika 1.18). Za razliku od klasičnog prilaza nadgledanog učenja gde se greška formira na osnovu željenog i stvarno dobijenog izlaza mreže, pojačano učenje (reinforcement learning) podrazumeva dovođenje na mrežu informacije da li je generisani izlaz pozitivan ili negativan (tačan ili netačan) i koristi tu informaciju da unapredi odzive kroz iteracije. Informacija o generisanom tačnom ili netačnom rezultatu se dovodi na mrežu u obliku realne ili logičke vrednosti  $r(t)$  koja predstavlja nagradu za dobro generisan rezultat ili kaznu ukoliko je rezultat loš. Lako je zaključiti da ovaj algoritam može biti efikasniji od algoritma nenadgledanog učenja pošto se mreža ocenjuje tokom rešavanja problema - čime na pravi način može ažurirati parametre s ciljem dobijanja pozitivnih ocena. Trening skup se sastoji od ulaznih podataka i vrednosti koje simbolizuju nagradu/kaznu i koji se nakon završetka svake sekvene obrade informacija dovode na mrežu. Signal pojačanja  $r(t)$  daje kvalitativnu ocenu ponašanja neuronske mreže. Poželjno je koristiti algoritam učenja kada referentni signal koji definiše željeno ponašanje neuronske mreže nije dostupan, ali je dostupan signal koji predstavlja ocenu njenog rada u smislu "dobro/loše".



Slika 1.18 Algoritam pojačanog učenja

Gotovo svi algoritmi učenja neuronskih mreža pripadaju jednoj od navedenih kategorija učenja ili su njihova varijacija. Potrebno je još pomenuti hibridni tip učenja koji kombinuje osobine nadgledanog i nenadgledanog učenja. Deo težinskih koeficijenata se određuje kroz proces nadgledanog učenja, dok se ostale vrednosti parametara dobijaju kroz samoorganizirajuću proceduru nenadgledanog učenja. U nastavku će biti detaljno predstavljen najpopularniji algoritam učenja sa propagacijom greške unazad kroz mrežu (*backpropagation učenje*).

## 1.4.2 Parametri algoritama učenja neuronskih mreža – stopa učenja i momentum faktor

### 1.4.2.1 Stopa učenja

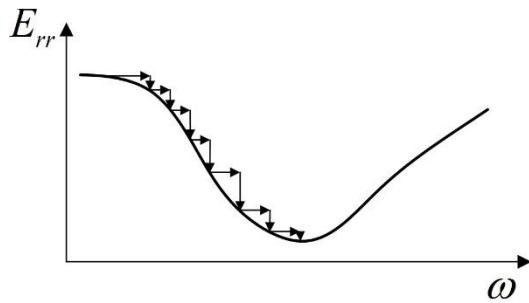
Stopa učenja je neizostavan parametar algoritma učenja koji utiče na brzinu kojom mreža ostvaruje željene rezultate i ima veliki uticaj na proces učenja. Stopa učenja ( $\eta$ ) proporcionalno utiče na promenu težinskih koeficijenata neurona mreže. Ako je vrednost  $\eta$  suviše velika, promena greške je skokovita i globalni minimum se može lako preskočiti. Dodatno, kretanje preko krive greške biće veoma nekontrolisano. Na drugoj strani, mala vrednost  $\eta$  može zahtevati neprihvatljivo veliko vreme učenja. U najvećem broju slučajeva stopa učenja ima vrednost između  $0.01 \leq \eta \leq 0.9$ . Optimalna vrednost parametra  $\eta$  zavisi od problema koji se rešava, strukture mreže i trening podataka, tako da je teško dati univerzalnu metodu za njen odabir. Ipak, poželjno je krenuti sa relativno velikim  $\eta$ , npr.  $\eta = 0.9$  i polako smanjivati do vrednosti 0.1. Za jednostavnije probleme stopa učenja se često može držati konstantnom.

Tokom treninga se može koristiti i promenljiva stopa učenja. Razlog za to je moguća promenljivost kvaliteta obrade podataka tokom iterativnog učenja. Na primer, u prvim iteracijama, velika stopa učenja može rezultirati dobijanjem dobrih rezultata, ali da tokom dalje obuke mreža ne usvaja nova znanja na željeni način. Dalje, manja stopa učenja je vremenski zahtevnija ali rezultira preciznijim rezultatima. Zbog toga je poželjno da se za vreme učenja stopa učenja smanjuje za jedan red veličine. Ipak, česta greška može da bude i kontinualno smanjenje stope učenja. Tada se dešava da smanjenje stope učenja bude veće od uspona „brda“ greške funkcije duž koje se penje. Kao rezultat toga dešava se zarobljavanje greške na tom usponu i prestanak njene konvergencije ka nuli.

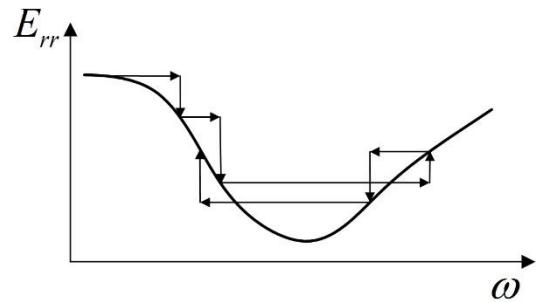
Stopa učenja pokazuje za koliko se, u pravcu najstrmijeg spuštanja, težine moraju šiftati po epohi. Prvi pristup podešavanja stope učenja je odabrati jedinstvenu vrednost za sve neurone mreže. Drugi pristup je da ne postoji globalna stopa učenja. Svaka težina ima svoju stopu koju ne postavlja korisnik već je mreža automatski bira tokom učenja. Optimalna stopa učenja bi trebala da smanjuje grešku što je brže moguće dok se proces vodi glatko niz površinu greške - ukoliko se kriva greške posmatra u odnosu na osu promena težina i srednjekvadratne greške (Slika 1.19). Vertikalni korak je količina redukovane greške za vreme svake epohe, a horizontalni korak odgovara podešavanju težine.

Slika 1.20 prikazuje efekat velike stope učenja. Veliki inkrementi promena težinskih koeficijenata (izazvani vrednošću stope učenja) mogu izazvati oscilatornost potrage za

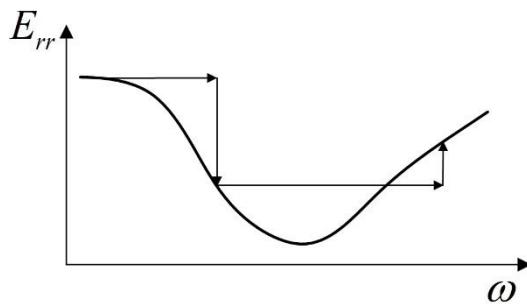
globalnim minimumom greške i čak, u nekim slučajevima, onemogućiti mrežu da pronađe taj minimum. Suviše velika stopa učenja nikada ne može dovesti do globalnog minimuma ako je inkrement težina suviše veliki i takav da pozicionira nove težine na bočnim stranama površine greške (Slika 1.21).



Slika 1.19 Optimalna stopa učenja za efikasnu minimizaciju greške



Slika 1.20 Efekat visoke stope učenja na obuku mreže



Slika 1.21 Efekat suviše visoke stope učenja na obuku mreže

Jedna od najefektivnijih metoda za ubrzavanje konvergencije *backpropagation* učenja je prilagođavanje parametra stope učenja tokom treninga. Mala vrednost parametara stope učenja prouzrokuje male promene težina u mreži iz jedne iteracije u sledeću, i to vodi do glatke krive učenja. Sa druge strane, ako je definisana velika vrednost parametra stope učenja kako bi se ubrzao proces obuke, to će rezultovati velikim promenama težina što može prouzrokovati nestabilnost i, kao rezultat, performanse mreže mogu postati oscilatorne. Da bi se ubrzala konvergencija i izbegla opasnost od nestabilnosti može se primeniti sledeće:

- Ako je promena ukupne srednjekvadratne greške istog algebarskog znaka u nekoliko uzastopnih epoha, onda parametar stope učenja treba povećati.
- Ako se algebarski znak ukupne srednjekvadratne greške menja u par uzastopnih epoha, onda stopu učenja treba smanjiti.

Adaptacija stope učenja zahteva izvesne promene u *backpropagation* algoritmu. Prvo, izlazi mreže i greške su izračunate na osnovu inicijalnog parametra stope učenja. Ako suma srednjekvadratne greške trenutne epohe prevaziđe prethodnu vrednost više nego što je to dozvoljeno i definisano, stopa učenja se smanjuje (tipično množenjem sa 0.7) i računaju se nove težine i aktivacioni pragovi. Sa druge strane, ako je greška manja od prethodne, stopa učenja se povećava (tipično množenjem sa 1.05).

Popularna metoda za upravljanje stope učenja je dodeljivanje velike vrednosti na početku treninga, a zatim njeno kontinuirano smanjenje kako bi se dobile tačne vrednosti finalnih težina. Metoda se implementira promenljivom veličinom koraka koji se određuje kao:

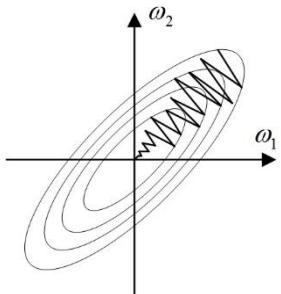
$$\eta(n+1) = \eta(n+1) - \beta, \quad (1.37)$$

gde je  $\eta(0) = \eta_0$  inicijalna veličina koraka a  $\beta$  mala konstanta. Veličina koraka se linearno smanjuje u svakoj iteraciji. Ukoliko postoji kontrola broja iteracija, može se početi sa velikim korakom koji se smanjuje praktično do 0 na kraju treninga. Vrednost  $\beta$  se određuje eksperimentalno. Svi neuroni jedne neuronske mreže trebalo bi da uče istom dinamikom. U praksi se, međutim, pokazalo da bi u nekim slučajevima neuroni sa više ulaza trebali da imaju manju stopu učenja od neurona sa manjim brojem ulaza.

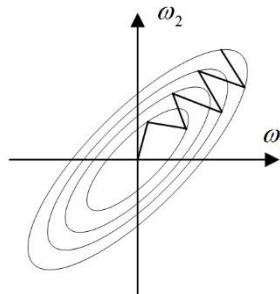
#### 1.4.2.2 Momentum faktor

Glavna osobina momentum faktora je da može uticati na stabilizaciju procesa učenja. Parametar može doprineti brzom prigušenju oscilacija i usmeravanju pretrage ka minimumu greške i dostizanju optimalnih vrednosti težina. Na slici 1.22 ilustrovan je *backpropagation* tip učenja bez i sa uključenim momentum faktorom. Uočljivo je da se uz prisustvo momentuma brže (u manje koraka) dolazi do željenih vrednosti težinskih koeficijenata. Momentum ubrzava proces minimizacije greške učenja u pravcu stabilne konvergencije performansi i usporava taj proces kada se nađe na potencijalne pikove i lokalne minime koje je potrebno izbeći (Slika 1.23). Na slici je ilustrativno prikazana lopta (vektor pozicije težina) kako se spušta niz brdo (karakterističnu površinu koja oslikava performanse sistema). Kada lopta dostigne poziciju lokalnog minimuma (pozicija 2) nastaviće da se kreće ukoliko je uključen momentum faktor. Time će biti nastavljena potraga za pozicijom globalnog minimum. Na drugoj strani, kretanje lopte bez uključenog momentuma biće završeno u poziciji lokalnog minimuma (pozicija 2) i svaka dalja iteracija (2, 3, 4, ...) neće doprineti nastavku poboljšanja performansi. Zbog toga se

učenje uz prisustvo momentuma smatra robustnom metodom za ubrzavanje procesa obuke mreže.



Slika 1.22 *Backpropagation* bez i sa momentum faktorom



Slika 1.23 Metoda opadajućeg gradijenta bez i sa uključenim momentum faktorom

Procedura uključenja momentum faktora u učenje mreže podrazumeva dovođenje momenta inercije (momentuma) pri svakom koraku (iteraciji). Jednačina ažuriranja težine uz prisustvo momentum faktora ( $\alpha$ ) može se predstaviti kao:

$$\Delta\omega_{i,j}(t) = \eta o_i \delta_j + \alpha \Delta\omega_{i,j}(t-1), \quad (1.38)$$

gde je  $\delta_j$  signal greške neurona  $j$  i  $o_i$  izlaz neurona  $i$  koji je ujedno ulaz neurona  $j$ . U praksi se pokazalo da je najefikasnija upotreba momentum faktora kada poseduje vrednost u intervalu od 0.6 do 0.9. Ako je kumulativna promena vrednosti težine u prethodnoj iteraciji u istom pravcu kao promena u trenutnoj, momentum će ubrzati njenu promenu. Ako je prethodna kumulativna promena težine u suprotnom pravcu u odnosu na trenutnu, ažuriranje težine biće usporeno i time se sprečavaju potencijalne oscilacije. Zaključno, inkrement promene težine proporcionalno zavisi od vrednosti njene promene u prethodnoj iteraciji. Stabilnost koju momentum faktor obezbeđuje pri dostizanju optimalnih težina izuzetno je korisna pri *online* učenju.

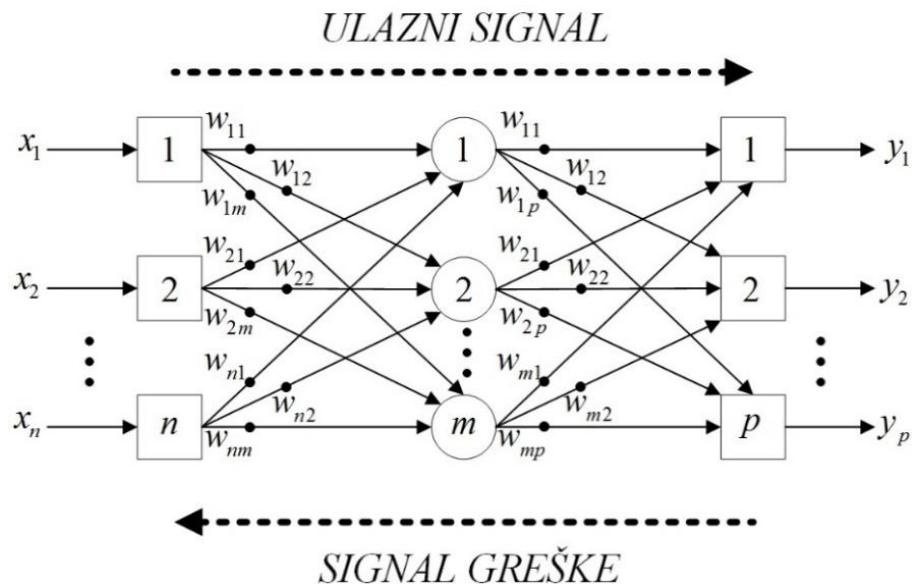
### 1.4.3 *Backpropagation* neuronska mreža

*Backpropagation* (BP) model neuronske mreže, baziran na algoritmu nadgledanog učenja, smatra se najpopularnijim i najkorišćenijim modelom današnjice. Smatra se da preko 90% komercijalnih i industrijskih aplikacija neuronskih mreža koriste BP algoritam. To je višeslojna mreža sa najčešće tri ili četiri sloja unutar njene strukture. Slojevi su u potpunosti povezani, što znači da je svaki neuron jednog sloja povezan sa svakim neuronom iz njegovog

susednog sloja. Učenje mreže u osnovi funkcioniše na sledeći način: mreža formira izlazni šablon informacija na osnovu startnih vrednosti težinskih koeficijenata i, ukoliko postoji greška na izlazu (razlika između željenog i dobijenog izlaza), težinski koeficijenti neurona se ažuriraju kako bi se minimizovala greška.

U BP neuronskoj mreži algoritam učenja se sastoji iz dve faze. Na početku prve faze se ulaznom sloju mreže dovode ulazne informacije. Mreža propagira ulazne informacije iz sloja u sloj dok se ne generiše na izlazu iz mreže izlazni skup informacija (izlazni šablon). Ukoliko je izlazni šablon različit od željenog izlaznog skupa informacija računa se greška i propagira unazad kroz mrežu - od izlaznog do ulaznog sloja. Na taj način se odvija druga faza učenja: propagiranje greške unazad kroz mrežu (čime se ažuriraju težinski koeficijenti u svakoj iteraciji).

Troslojna mreža sa slike 1.24 biće iskorišćena za implementaciju BP algoritma učenja. Indeksi  $n, m$  i  $p$  predstavljaju brojeve neurona ulaznog, skrivenog i izlaznog sloja, respektivno. Ulazni signali  $x_1, x_2, \dots, x_n$  se propagiraju kroz mrežu od ulaznog ka izlaznom sloju, dok se signali greške  $e_1, e_2, \dots, e_p$  propagiraju od izlaza ka ulazu. Simbol  $w_{nm}$  označava težinu konekcije između neurona  $n$  ulaznog sloja i neurona  $m$  skrivenog sloja. Simbol  $w_{mp}$  označava težinu konekcije između neurona  $m$  skrivenog sloja i neurona  $p$  izlaznog sloja.



Slika 1.24 Troslojna BP neuronska mreža

Signal greške na izlazu neurona  $p$  u iteraciji  $k$  može se definisati kao:

$$e_p(k) = y_{dp}(k) - y_p(k), \quad (1.39)$$

gde je  $y_{dp}(k)$  željeni izlaz neurona  $p$  u iteraciji  $k$ , a  $y_p(k)$  stvarno dobijeni izlaz. Pravilo ažuriranja težina izlaznog sloja glasi:

$$w_{mp}(k+1) = w_{mp}(k) + \Delta w_{mp}(k), \quad (1.40)$$

gde je  $\Delta w_{mp}(k)$  korektivni faktor težine  $w_{mp}$  u iteraciji  $k$ . Kod višeslojnih neuronskih mreža izračunavanje  $\Delta w_{mp}(k)$  se može uraditi na sledeći način:

$$\Delta w_{mp}(k) = \alpha \cdot y_m(k) \cdot \delta_p(k), \quad (1.41)$$

gde je  $y_m(k)$  izlaz neurona  $m$  u skrivenom sloju u iteraciji  $k$ , a  $\delta_p(k)$  gradijent greške neurona  $p$  izlaznog sloja takođe u iteraciji  $k$ . Gradijent greške neurona se određuje kao izvod aktivacione funkcije multiplikovan greškom na izlazu tog neurona. Za neuron  $p$  izlaznog sloja važi:

$$\delta_p(k) = \frac{\partial y_p(k)}{\partial X_p(k)} \cdot e_p(k), \quad (1.42)$$

gde je  $y_p(k)$  izlaz neurona u iteraciji  $k$ , a  $X_p(k)$  je težinski ulaz mreže neurona  $p$  u istoj iteraciji. Ukoliko je korišćena sigmoidna aktivaciona funkcija, jednačina (1.42) može da se napiše u obliku:

$$\delta_p(k) = \frac{\partial \left\{ \frac{1}{1 + \exp[-X_p(k)]} \right\}}{\partial X_p(k)} \cdot e_p(k) = \frac{\exp[-X_p(k)]}{\left\{ 1 + \exp[-X_p(k)] \right\}^2} \cdot e_p(k). \quad (1.43)$$

Pošto je sigmoidna aktivaciona funkcija definisana kao:

$$y_p(k) = \frac{1}{1 + \exp[-X_p(k)]}, \quad (1.44)$$

lako se može zaključiti da se gradijent greške neurona  $p$  može predstaviti u obliku:

$$\delta_p(k) = y_p(k) \cdot [1 - y_p(k)] \cdot e_p(k). \quad (1.45)$$

Izračunavanje korektivnog faktora  $\Delta w_{nm}(k)$  neurona  $m$  skrivenog sloja može se izvršiti primenom iste jednačine koja je korišćena i za izlazni sloj:

$$\Delta w_{nm}(k) = \alpha \cdot x_n(k) \cdot \delta_m(k), \quad (1.46)$$

gde je  $\delta_m(k)$  gradijent greške neurona  $m$  u skrivenom sloju i može se izraziti kao:

$$\delta_m(k) = y_m(k) \cdot [1 - y_m(k)] \cdot \sum_{i=1}^p \delta_i(k) \cdot w_{mi}(k). \quad (1.47)$$

Vrednost  $y_m(k)$  može da se izračuna iz jednačine:

$$y_m(k) = \frac{1}{1 + e^{-X_m(k)}}. \quad (1.48)$$

Nepoznati član  $X_m(k)$  iz (47) može se izraziti kao:

$$X_m(k) = \sum_{i=1}^n x_i(k) \cdot w_{im}(k) - b_m, \quad (1.49)$$

gde je  $n$  broj neurona u ulaznom sloju, a  $b_m$  odgovarajući prag osetljivosti za  $m$ -ti neuron skrivenog sloja. U nastavku će kroz pojedinačne korake biti predstavljena procedura formiranja BP neuronske mreže.

### **Korak 1: Definisanje strukture neuronske mreže**

- **Broj neurona u ulaznom i izlaznom sloju.** Broj neurona u ulaznom i izlaznom sloju se može definisati na osnovu kompleksnosti problema za koji je potrebno obučiti mrežu, broju ulaznih promenljivih koje je potrebno uzeti u razmatranje i formatu (dimenziji) željenog izlaznog rezultata mreže.

- **Broj neurona u skrivenom sloju.** Broj neurona odgovara broju slobodnih parametara kojima se može matematički opisati problem koji se rešava. Ne postoji univerzalno rešenje pri odabiru broja neurona. Najbolji prilaz je treniranje mreže koja sadrži nekoliko neurona uz postepeno povećavanje broja neurona dok se ne dobiju željeni rezultati, odnosno, dok željene performanse generalisanja nisu dostignute. Pri formiranju mreže, kao gruba aproksimacija može se uzeti da skriveni sloj sadrži polovinu broja neurona ulaznog sloja. Za izabrani mali broj skrivenih neurona vreme proračuna mreže u svakoj iteraciji biće kratko (pošto je broj težina koje je potrebno ažurirati mali). Za proces konvergencije performansi takve mreže može biti potreban veliki broj trenažnih iteracija. Razlog za to je što mreža sa malim brojem neurona nema mnogo slobode i fleksibilnosti za prilagođavanje težinskih koeficijenata prilikom učenja. Sa druge strane, ukoliko se izabere veliki broj neurona u skrivenom sloju, proračunsko vreme po svakoj iteraciji biće veće usled ažuriranja velikog broja težina. Ipak, konvergencija performansi mreže se u tom slučaju može ostvariti uz manji broj iteracija.

• **Stopa učenja i momentum faktor.** Upotrebom jednačina (1.37) i (1.38) pronaći optimalne vrednosti stope učenja  $\eta$  i momentum faktora  $\alpha$  koje utiču na brzinu konvergencije i dostizanje željenog stanja.

• **Broj iteracija.** Broj iteracija koji je potreban za obuku mreže zavisi od mnogo faktora: vrednosti konstantnih koeficijenata, broja neurona, kriterijuma za prekid treninga, nivoa kompleksnosti trening podataka. Može se kretati već od nekoliko desetina pa i do par desetina hiljada iteracija.

### Korak 2: Inicijalizacija

Težinski koeficijenti se inicijalizuju sa malim proizvoljnim vrednostima. Inicijalizacija težina nije trivijalan problem i od nje zavisi efikasnost mreže prilikom obuke. Ukoliko se izabere naizgled jednostavno rešenje i sve težine postave na vrednost 0, njihovo ažuriranje tokom procesa učenja neće biti moguće i trenažni proces biće neefikasan. Ukoliko se sve inicijalne težine postave na istu vrednost one će se u podjednakoj meri ažurirati tokom vremena - što takođe nije optimalno rešenje. Jedno od rešenja ovog problema je simetrično postavljanje vrednosti u okviru zadatog opsega, npr. [-0.5; 0.5], izbegavajući pritom nulte vrednosti i vrednosti bliske nuli. Drugo rešenje podrazumeva podešavanje svih težine i pragova aktivacija mreže na proizvoljne brojeve koji se nalaze u rangu:

$$\left( -\frac{2.4}{N_i}, +\frac{2.4}{N_i} \right), \quad (1.50)$$

gde je  $N_i$  ukupan broj ulaza neurona  $i$ . Inicijalizacija težina vrši se za svaki neuron pojedinačno.

### Korak 3: Aktivacija

• Aktivirati BP neuronsku mrežu dovođenjem odgovarajućih ulaza  $x_1(k), x_2(k), \dots, x_n(k)$  i željenih izlaza  $y_{d1}(k), y_{d2}(k), \dots, y_{dn}(k)$ .

• Izračunati izlaze neurona u skrivenom sloju:

$$y_m(k) = \text{sigmoid} \left[ \sum_{i=1}^l x_i(k) \cdot w_{im}(k) - b_m \right], \quad (1.51)$$

gde je  $l$  broj ulaza neurona  $m$  u skrivenom sloju.

• Izračunati stvarne izlaze neurona u izlaznom sloju:

$$y_p(k) = \text{sigmoid} \left[ \sum_{i=1}^e x_{ip}(k) \cdot w_{ip}(k) - b_p \right], \quad (1.52)$$

gde je  $e$  broj ulaza neurona  $p$  u izlaznom sloju.

#### **Korak 4: Ažuriranje težina**

Ažuriranje težina BP mreže izvršava se propagiranjem grešaka izlaznih neurona unazad na sledeći način:

- Izračunati gradijent greške za neurone u izlaznom sloju:

$$\delta_p(k) = y_p(k) \cdot [1 - y_p(k)] \cdot e_p(k), \quad (1.53)$$

gde je:

$$e_p(k) = y_{dp}(k) - y_p(k). \quad (1.54)$$

- Izračunati vrednosti težinskih koeficijenata:

$$\Delta w_{mp}(k) = \alpha \cdot y_m(k) \cdot \delta_p(k). \quad (1.55)$$

- Ažurirati težine izlaznih neurona:

$$w_{mp}(k+1) = w_{mp}(k) + \Delta w_{mp}(k). \quad (1.56)$$

- Izračunati gradijent greške za neurone u skrivenom sloju:

$$\delta_m(k) = y_m(k) \cdot [1 - y_m(k)] \sum_{e=1}^p \delta_e(k) \cdot w_{me}(k). \quad (1.57)$$

- Izračunati korektivne faktore težina:

$$\Delta w_{nm}(k) = \alpha \cdot x_n(k) \cdot \delta_m(k). \quad (1.58)$$

- Ažurirati vrednosti težina u skrivenom sloju:

$$w_{nm}(k+1) = w_{nm}(k) + \Delta w_{nm}(k). \quad (1.59)$$

#### **Korak 5: Iteracija**

Povećati iteraciju  $k$  za jedan, vratiti se na korak 3 i ponoviti proces dok kriterijum greške nije zadovoljen. Obuka mreže se završava kada su postignuti željeni rezultati (kada je definisani kriterijum evaluacije ispunjen).

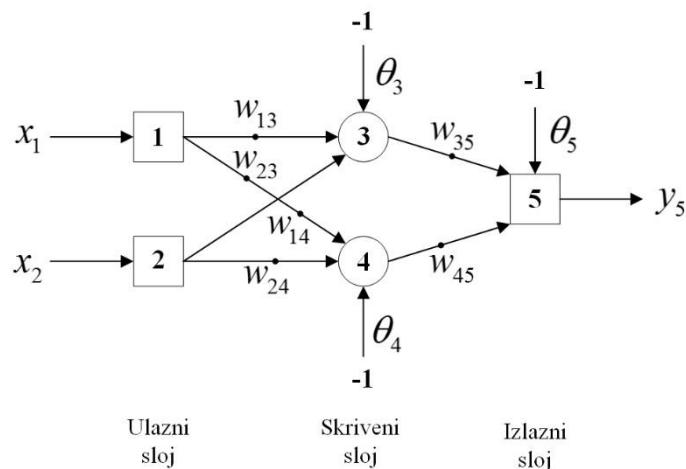
### 1.4.3.1 Primer funkcionisanja Backpropagation algoritma učenja

U narednom primeru biće prikazan način ažuriranja težinskih koeficijenata i aktivacionih pragova u jednoj iteraciji na primeru troslojne mreže (2-2-1) za potrebe realizacije logičke operacije ekskluzivno *ILI*. Tabela istinitosti ekskluzivnog *ILI* kola data je ispod. Problem nije linearno separabilan što znači da nije moguće iskoristiti perceptron.

Tabela 1.3 Tabela istinitosti ekskluzivno *ILI* operacije

Ulazi	Izlaz	
$x_1$	$x_2$	$y$
0	0	0
0	1	1
1	0	1
1	1	0

Izgled troslojne neuronske mreže prikazan je na sledećoj slici:



Slika 1.25 Troslojna neuronska mreža (2-2-1)

Neuroni 1 i 2 ulaznog sloja prihvataju ulaze  $x_1$  i  $x_2$ , respektivno, i propagiraju ih do neurona skrivenog sloja bez bilo kakvog procesiranja. Na osnovu toga važi:

$$\begin{aligned} x_{13} &= x_{14} = x_1, \\ x_{23} &= x_{24} = x_2. \end{aligned} \quad (1.60)$$

Efekat aktivacionog praga primjenjenog na neuron u skrivenom ili izlaznom sloju predstavljen je svojom težinom  $\theta$  koja je pobuđena fiksnom ulaznom vrednošću -1. Inicijalne težine i aktivacioni pragovi su proizvoljno odabrani sa vrednostima:  $w_{13} = 0.5$ ,  $w_{14} = 0.9$ ,  $w_{23} = 0.4$ ,  $w_{24} = 1.0$ ,  $w_{35} = -1.2$ ,  $w_{45} = 1.1$ ,  $\theta_3 = 0.8$ ,  $\theta_4 = -0.1$ ,  $\theta_5 = 0.3$ .

Neka je trening skup takav da su vrednosti  $x_1 = 1$  i  $x_2 = 1$ . Na osnovu tabele 3 željeni izlaz  $y_{d,5} = 0$ . Stvarni izlazi neurona 3 i 4 u skrivenom sloju se mogu izračunati kao:

$$y_3 = \text{sigmoid}(x_1 \cdot w_{13} + x_2 \cdot w_{23} - \theta_3) = \frac{1}{1+e^{-(1 \times 0.5 + 1 \times 0.4 - 1 \times 0.8)}} = 0.5250, \quad (1.61)$$

$$y_4 = \text{sigmoid}(x_1 \cdot w_{14} + x_2 \cdot w_{24} - \theta_4) = \frac{1}{1+e^{-(1 \times 0.9 + 1 \times 1.0 + 1 \times 0.1)}} = 0.8808. \quad (1.62)$$

Sada se može izračunati i izlaz neurona 5 izlaznog sloja:

$$y_5 = \text{sigmoid}(y_3 \cdot w_{35} + y_4 \cdot w_{45} - \theta_5) = \frac{1}{1+e^{(-0.5250 \times 1.2 + 0.8808 \times 1.1 - 1 \times 0.3)}} = 0.5097. \quad (1.63)$$

Na osnovu stvarne vrednosti izlaza neurona 5 može se formirati i signal greške:

$$e = y_{d,5} - y_5 = 0 - 0.5097 = -0.5097. \quad (1.64)$$

Sledeći korak je treniranje težina. Da bi se izvršilo njihovo ažuriranje potrebno je propagirati grešku  $e$  unazad od izlaznog sloja ka ulaznom. Prvo se računa gradijent greške neurona 5 u izlaznom sloju:

$$\delta_5 = y_5 \cdot (1 - y_5) \cdot e = 0.5097 \times (1 - 0.5097) \times (-0.5097) = -0.1274. \quad (1.65)$$

Sada se mogu odrediti korekcije težina, ukoliko se uzme u obzir da je zadata stopa učenja  $\alpha = 0.1$ :

$$\Delta w_{35} = \alpha \times y_3 \times \delta_5 = 0.1 \times 0.5250 \times (-0.1274) = -0.0067, \quad (1.66)$$

$$\Delta w_{45} = \alpha \times y_4 \times \delta_5 = 0.1 \times 0.8808 \times (-0.1274) = -0.0112, \quad (1.67)$$

$$\Delta \theta_5 = \alpha \times (-1) \times \delta_5 = 0.1 \times (-1) \times (-0.1274) = 0.0127. \quad (1.68)$$

Dalje, izračunava se gradijent greške neurona 3 i 4 u skrivenom sloju:

$$\delta_3 = y_3 \times (1 - y_3) \times \delta_5 \times w_{35} = 0.5250 \times (1 - 0.5250) \times (-0.1274) \times (-1.2) = 0.0381, \quad (1.69)$$

$$\delta_4 = y_4 \times (1 - y_4) \times \delta_5 \times w_{45} = 0.8808 \times (1 - 0.8808) \times (-0.1274) \times 1.1 = -0.0147. \quad (1.70)$$

Nakon toga se određuju korekcije preostalih težina:

$$\Delta w_{13} = \alpha \times x_1 \times \delta_3 = 0.1 \times 1 \times 0.0381 = 0.0038, \quad (1.71)$$

$$\Delta w_{23} = \alpha \times x_2 \times \delta_3 = 0.1 \times 1 \times 0.0381 = 0.0038, \quad (1.72)$$

$$\Delta w_{14} = \alpha \times (-1) \times \delta_4 = 0.1 \times (-1) \times (-0.0147) = 0.0147, \quad (1.73)$$

$$\Delta w_{24} = \alpha \times x_2 \times \delta_4 = 0.1 \times 1 \times (-0.0147) = -0.0147, \quad (1.74)$$

$$\Delta w_{24} = \alpha \times x_2 \times \delta_4 = 0.1 \times 1 \times (-0.0147) = -0.0015, \quad (1.75)$$

$$\Delta \theta_4 = \alpha \times (-1) \times \delta_4 = 0.1 \times (-1) \times (-0.0147) = 0.0015. \quad (1.76)$$

Na kraju je potrebno izvršiti ažuriranje svih težina i aktivacionih pragova u neuronskoj mreži:

$$w_{13} = w_{13} + \Delta w_{13} = 0.5 + 0.0038 = 0.5038, \quad (1.77)$$

$$w_{14} = w_{14} + \Delta w_{14} = 0.9 - 0.0015 = 0.8985, \quad (1.78)$$

$$w_{23} = w_{23} + \Delta w_{23} = 0.4 + 0.0038 = 0.4038, \quad (1.79)$$

$$w_{24} = w_{24} + \Delta w_{24} = 1.0 - 0.0015 = 0.9985, \quad (1.80)$$

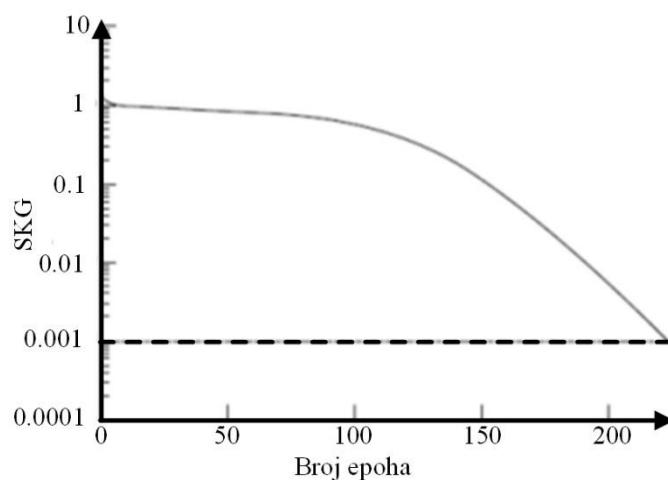
$$w_{35} = w_{35} + \Delta w_{35} = -1.2 - 0.0067 = -1.2067, \quad (1.81)$$

$$\theta_3 = \theta_3 + \Delta \theta_3 = 0.8 - 0.0038 = 0.7962, \quad (1.82)$$

$$\theta_4 = \theta_4 + \Delta \theta_4 = -0.1 + 0.0015 = -0.0985, \quad (1.84)$$

$$\theta_5 = \theta_5 + \Delta \theta_5 = 0.3 + 0.0127 = 0.3127. \quad (1.85)$$

Ovim je završena procedura ažuriranja težina u jednoj iteraciji. Trenažni proces se ponavlja dok suma kvadratnih grešaka (SKG) nije manja od zadate vrednosti. Slika 1.26 predstavlja krivu učenja: broj epoha trening procesa je prikazan na x osi a suma kvadratnih grešaka na y osi. Kriva učenja prikazuje koliko neuronska mreža brzo uči. Sa slike se vidi da je potrebno 224 epoha da greška mreže postane manja od željene ( $SKG=0.001$ ).



Slika 1.26 Konvergencija greške neuronske mreže

Nakon 224 trening epoha težinski koeficijenti i aktivacioni pragovi imaju sledeće vrednosti:  $w_{13} = -6.3041$ ,  $w_{14} = -5.7896$ ,  $w_{23} = 6.2288$ ,  $w_{24} = 6.0088$ ,  $w_{35} = 9.6657$ ,  $w_{45} = -9.4242$ ,  $\theta_3 = 3.3858$ ,  $\theta_4 = -2.8976$ ,  $\theta_5 = -4.4859$ .

Konačni rezultati se mogu prikazati i tabelarno:

Tabela 1.4 Ostvareni rezultati troslojne neuronske mreže po završetku treninga

Ulazi		Željeni izlaz	Dobijeni izlaz	Greška	SKG
$x_1$	$x_2$	$y_d$	$y_5$	$e$	0.0010
1	1	0	0.0155	-0.0155	
0	1	1	0.9849	0.0151	
1	0	1	0.9849	0.0151	
0	0	0	0.0175	-0.0175	

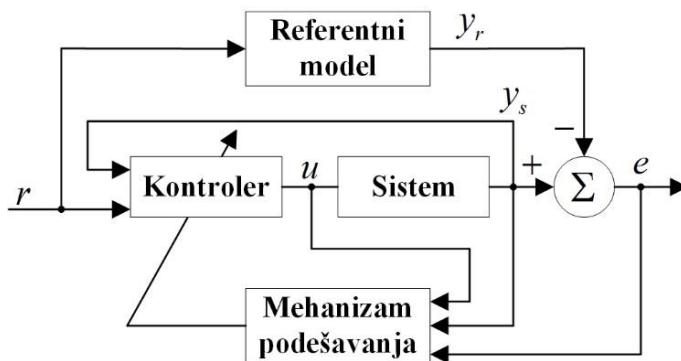
## **2 Motivacija za upotrebu veštačkih neuronskih mreža u upravljanju dinamičkim sistemima**

### **2.1 Primena veštačkih neuronskih mreža u upravljanju**

Realizacija upravljačkih logika baziranih na inteligentnim algoritmima upravljanja sve je popularnija u oblasti tehnike i inženjeringu. Veliku upotrebnu vrednost u okviru svih tipova intelligentnog upravljanja zauzimaju veštačke neuronske mreže. Cilj upotrebe mreže je postizanje željenih performansi sistema u skladu sa zadatim specifikacijama. Mreže se mogu koristiti kao zamene konvencionalnim kontrolerima, mogu biti njihova dopuna ili nadogradnja. Postizanje željenih performansi upotrebom konvencionalnih kontrolera može biti otežano ukoliko sistem poseduje izvesnu stopu neodređenosti i nelinearnosti. Neuronske mreže su se kroz praksu pokazale kao intelligentni sistemi koji se mogu adaptirati i uspešno rešiti pojavu signala poremećaja i nelinearnosti usled rada. Takođe, neuronske mreže imaju veliku upravljačku primenu u sistemima za koje ne postoji dovoljno informacija i koji se matematički ne mogu u potpunosti opisati. Nedostatak tih informacija prouzrokuje nemogućnost formiranja kompletног, već formiranja samo parcijalnog modela sistema. Zbog toga upotreba konvencionalnih kontrolera u tim slučajevima nije moguća u potpunosti i preporuka je upotreba intelligentne strukture koja bi nadomestila te nedostatke. Upotreba neuronskih mreža može pomoći sistemu da dobije karakteristiku intelligentnosti i samostalnosti, da zameni ljude pri izvršavanju opasnih i niza ponovljenih zadataka i može unaprediti performanse u odnosu na one koje bi se ostvarile pod upravljanjem od strane čoveka.

U oblastima tehnike, obradi informacija i predikcije, veštačke neuronske mreže se primenjuju za modeliranje biološkog mozga, modeliranje realnih aplikacija, finansijsko modeliranje, predikcije na tržištu i obradu vremenski zavisnih sekvenci podataka. Takođe, mreže nalaze primenu u video igramu u kojima je važna veštačka inteligencija računara, robotici (gde se koriste za realizaciju autonomnih adaptivnih robova), u aplikacijama prepoznavanja šablonu, analizi, kompresiji i pretrazi podataka, bioinformatici i realizaciji direktnih i indirektnih adaptivnih upravljačkih logika. Od navedenih primena, za potrebe ove doktorske disertacije, biće razvijene neuronske mreže za potrebe adaptivnog upravljanja nelinearnim sistemima, predikcije vremenskih sekvenci i modeliranja realnih sistema.

Direktno i indirektno adaptivno upravljanje su dve osnovne metode za implementaciju neuronskih mreža unutar upravljačkih logika sistema. Direktno adaptivno upravljanje (Slika 2.1) se primenjuje kada postoji realizovani matematički model sistema. Na drugoj strani, indirektno adaptivno upravljanje (Slika 2.2) se primenjuje kada model sistema ne postoji, već se sistem mora modelirati upotrebom druge neuronske mreže. Elementarni tipovi obe metode koriste *backpropagation* algoritam učenja pri ažuriranju vrednosti težinskih koeficijenata.

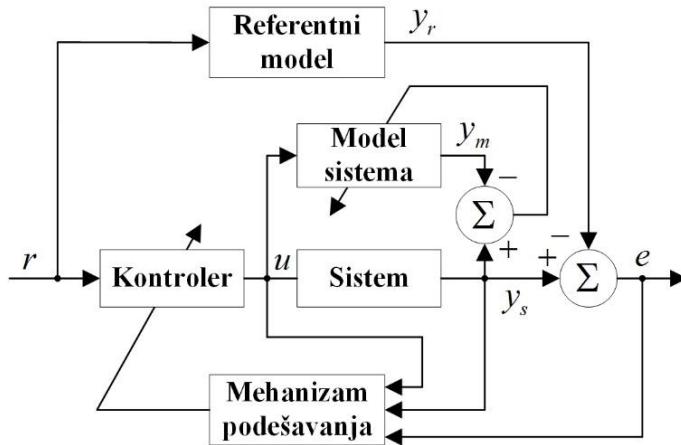


Slika 2.1 Direktno adaptivno upravljanje

Nedostatak direktnog adaptivnog upravljanja je neupotrebljivost pri nedostatku informacija o sistemu. Za razliku od njega, indirektno adaptivno upravljanje ne zahteva prethodna znanja i informacije koje opisuju sistem i može se upotrebiti na potpuno nepoznatom modelu. Za realizaciju indirektnog upravljanja potrebno je formiranje dve neuronske mreže: jedne koja će predstavljati model sistema i druge koja ima funkciju regulatora. Blok dijagram indirektnog adaptivnog upravljanja prikazan je na slici 2.2. Neuronska mreža koja predstavlja model sistema je mreža sa propagiranjem informacija unapred (*feedforward* mreža). Za njenu realizaciju potrebno je izvršiti trening u *offline* režimu sa bazom trening podataka dovoljno velikom za adekvatnu obuku mreže. Adaptivnost upravljanja podrazumeva da se trenažni procesi obe neuronske mreže izvršavaju i *online*, što znači da se tokom rada sistema parametri mreža i dalje podešavaju skladno promenama signala.

Upotreba neuronskih mreža u realnim upravljačkim sistemima pruža optimalne rezultate najčešće u kombinaciji sa postojećim upravljačkim logikama, odnosno, njihovim zajedničkim funkcionisanjem. Svoju primenu imaju takođe u okviru kompleksnih upravljačkih sistema gde se generalni problem upravljanja može svesti na niz jednostavnih problema i zadataka koje je potrebno izvršiti. Neuronsku mrežu tada nije neophodno vezivati za rešavanje celokupnog

problema, već je u skladu sa njenim mogućnostima moguće upotrebiti za rešavanje jednog podskupa zadataka.



Slika 2.2 Indirektno adaptivno upravljanje

Neke od bitnijih karakteristika veštačkih neuronskih mreža zbog kojih ih je moguće koristiti pri realizaciji različitih upravljačkih logika su:

- Ulagano-izlagano mapiranje – podrazumeva modifikaciju težinskih koeficijenata neuronske mreže tokom procesa učenja. Skup trening podataka sastoji se od jedinstvenih vektora ulaznih i izlaznih vrednosti neuronske mreže. Trening se ponavlja na većem broju uzoraka sve dok mreža ne postigne željene performanse i slobodni parametri (težine) ne dođu u ustaljeno stanje. Prethodno dovedeni podaci mogu se ponovo dovesti tokom treninga na mrežu ali u drugačijem redosledu. Opisanom procedurom mreža vrši ulagano-izlagano mapiranje podataka i, na osnovu postignutog kvaliteta mapiranja, sa više ili manje uspeha vršiće procesiranje nepoznatih podataka.
- Nelinearnost – osobina koja omogućava adekvatno učenje i aproksimaciju nelinearnih karakteristika.
- Adaptivnost – osobina koja se iskazuje ažuriranjem i prilagođavanjem težinskih koeficijenata mreže na promene koje se dešavaju u okruženju. Adaptivnost predstavlja i glavnu prednost upotrebe neuronskih mreža u realnim upravljačkim sistemima u odnosu na konvencionalne kontrolere. Primeri promena u okruženju mogu biti šumovi i poremećaji. Konvencionalni kontroleri mogu imati visok stepen osetljivosti na pojavu poremećaja što može rezultirati nestabilnim radom sistema. Na drugoj strani, upravljački sistemi sa implementiranim neuronskim mrežama imaju veću sposobnost adaptacije na poremećaje što kao krajnji efekat ima stabilniji i robustniji rad sistema pod njihovim dejstvom. Zasluge za to ima i mogućnost

online učenja mreže (u realnom vremenu) kojim se i tokom pojave poremećaja parametri mreže prilagođavaju na novonastale promene.

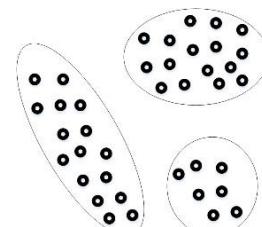
- Tolerancija na greške – karakteristika usko povezana sa osobinom adaptivnosti mreže. Neuronska mreža ima potencijal tolerancije na greške u smislu da se njene performanse neznatno menjaju pri pojavi poremećaja i nestabilnosti. Na primer, neka se poremećaj odlikuje oštećenjem ulazno-izlaznih konekcija jednog neurona mreže koji prouzrokuje na izlazu odziv lošijeg kvaliteta. Taj poremećaj, međutim, ne mora da znači i generisanje nedozvoljeno loših rezultata na izlazu mreže. Osobina tolerancije na greške je posledica distributivnosti i paralelizma protoka informacija kroz mrežu, što znači da će umesto neupotrebljivih izlaznih vrednosti mreža pružiti zanemarljivo lošije rezultate od onih optimalnih. Poremećaj koji deluje na mrežu mora biti velikog obima i značajno veći deo strukture mreže treba biti zahvaćen njime da bi ukupan odziv mreže bio u toj meri degradiran da je neupotrebljiv. Za razliku od mreža, ukoliko dođe do neke nefunkcionalnosti kod konvencionalnih kontrolera velika je verovatnoća da generisani upravljački signal neće biti nimalo upotrebljiv.

- Uniformnost dizajna – osobina koja podrazumeva da model neurona predstavlja zajedničku komponentu svih neuronskih mreža. To omogućava fleksibilnost pri modifikacijama struktura samih mreža i jednostavnost implementacije velikog broja različitih algoritama učenja u postojećim strukturama. Takođe, uniformnost dizajna omogućava formiranje hibridnih i modularnih struktura zasnovanih na integraciji više neuronskih mreža unutar jedne funkcionalne celine (što će biti prikazano u poglavlju 8). U nastavku će biti prikazani primeri upotrebe neuronskih mreža za rešavanje različitih tipova problema.

Problem klasifikacije šablonu podrazumeva rešavanje problema vezivanja ulaznog vektora podataka za jednu od više unapred specificiranih klasa. Na slici 2.3 dat je primer kardiograma koji na osnovu klasifikacionog procesa neuronske mreže treba da generiše jednu od dve klase izlaznih rezultata: kardiološki rezultat je dobar ili kardiološki rezultat je loš. Pored prepoznavanja i klasifikacije EKG signala, neke od poznatijih aplikacija klasifikacije šablonu su prepoznavanje karaktera, prepoznavanje govora, provera kvaliteta štampanog kola...



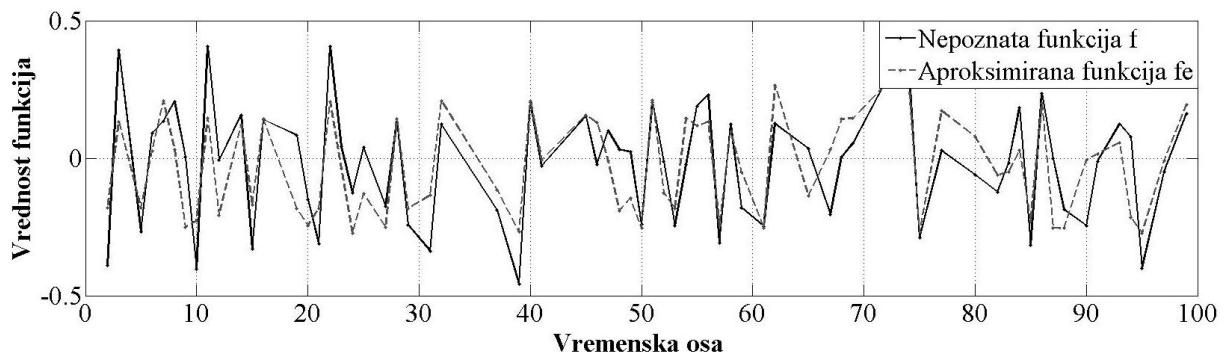
Slika 2.3 Klasifikacija podataka



Slika 2.4 Klasterizacija podataka

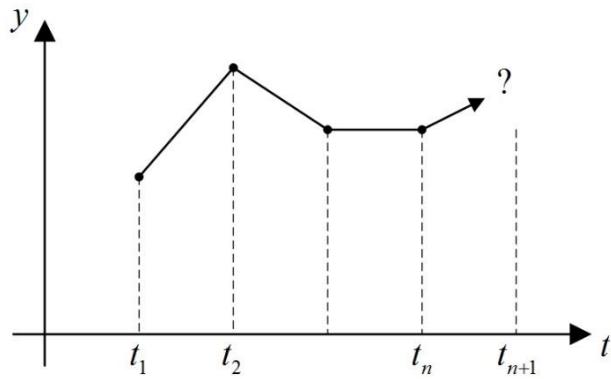
Naredni primer vezan je za klasterizaciju, odnosno, grupisanje podataka. Klasterizacija se naziva još i nenadgledanom obradom podataka pošto ne postoje unapred pripremljene klase koje bi mreža naučila na osnovu trening podataka. Trening podaci ne postoje već algoritam grupisanja istražuje sličnosti među podacima, formira šablone i postavlja slične podatke unutar grupa (Slika 2.4). Neke od aplikacija koje uključuju klasterizaciju podataka su aplikacije pretraživanja podataka (*data mining* aplikacije), aplikacije za kompresiju i analizu podataka.

Aproksimacija funkcije je još jedan popularan problem za rešavanje upotrebom veštačkih neuronskih mreža. Neka se trening skup sastoji od  $n$  ulazno-izlaznih skupova podataka  $((x_1, y_1), (x_2, y_2), \dots, (x_n, y_n))$  generisanih od strane nepoznate funkcija  $f(x)$ . Zadatak aproksimacije je naći estimiranu vrednost  $f_e$  nepoznate funkcije  $f$ . Upotrebljena vrednost aproksimacije funkcija pomoću neuronskih mreža nalazi se u rešavanju mnogih inženjerskih i naučnih problema modeliranja. Na slici 2.5 prikazana je komparacija rezultata nepoznate funkcije  $f$  i njene aproksimacije  $f_e$  pomoću neuronske mreže. Uočljiva je razlika između dva dobijena signala. Cilj treninga mreža je minimizovati tu razliku što je više moguće i, u idealnom slučaju, dobiti rezultat koji podrazumeva poklapanje dve karakteristike.

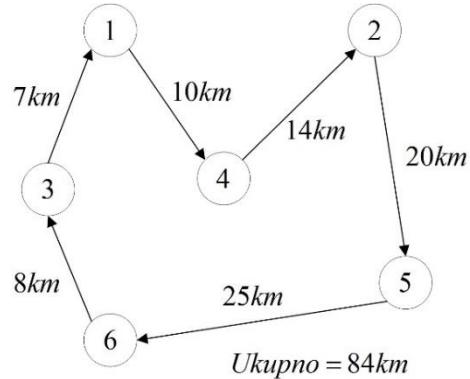


Slika 2.5 Aproksimacija funkcije

Za problem predikcije podataka dat je skup sa  $n$  elemenata  $(y(t_1), y(t_2), \dots, y(t_n))$ , gde je  $y(t_i)$  vrednost promenljive  $y$  u vremenskom trenutku  $t_i$ . Zadatak predikcije je predviđanje vrednosti promenljive u vremenskom trenutku  $t_{n+1}$  na osnovu procesiranih informacija iz svih prethodnih uzoraka (Slika 2.6). Tipične aplikacije bazirane na prediktivnim tipovima neuronskih mreža su predikcije na tržištu, vremenska prognoza, predikcija kursa novčane valute, predviđanje potrošnje električne energije, itd.



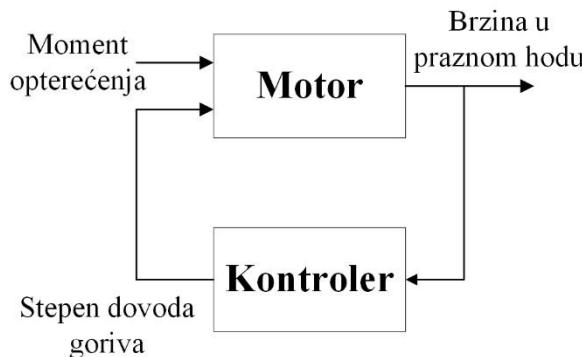
Slika 2.6 Predikcija vrednosti promenljive  $y$



Slika 2.7 Problem putujućeg trgovca

Cilj optimizacionih inteligentnih algoritama je naći optimalno rešenje problema koje se kreće u okviru zadatih ograničenja. U oblastima tehnike, matematike, fizike i ekonomije postoji veliki broj zadataka za čije je rešavanje potrebna neka od brojnih optimizacionih tehnika. Na slici 2.7 je predstavljen problem putujućeg trgovca gde je cilj utvrditi najkraću rutu koju trgovac treba da pređe a da obide svih 6 gradova.

Upotreba veštačkih neuronskih mreža za potrebe upravljanja dinamičkim sistemima je i najvažnija primena mreža u oblasti tehnike i intelligentnih sistema. Razmatra se upravljački sistem definisan skupom podataka  $\{u(t), y(t)\}$ , gde je  $u(t)$  upravljački ulaz a  $y(t)$  je rezultujući izlaz sistema u vremenu  $t$ . U referentnom modelu adaptivnog upravljanja, cilj je generisati takav upravljački ulaz  $v(t)$  da sistem prati zadatu trajektoriju. Primer upravljanja dinamičkim sistemom dat je na slici 2.8 gde je objekat upravljanja motor automobila, a zadatak je kontrola kretanja pri praznom hodu. Definisano je da upravljanje zavisi od momenta opterećenja automobila i od količine goriva dovedenog kao pogon motora.



Slika 2.8 Upravljanje motorom automobila pomoću kontrolera intelligentne strukture

## 2.2 Trenutno stanje razvoja ortogonalnih i endokrinih neuronskih mreža

Standardne neuronske mreže su detaljno opisane u prvom poglavlju. U ovoj disertaciji akcenat je na realizaciji novih tipova adaptivnih neuronskih mreža zasnovanih na veštačkom endokrinom faktoru. Endokrini faktor će biti detaljno predstavljen u poglavlju 6, a u ovom potpoglavlju biće dat osvrt na dosadašnji razvoj i primenu endokrinih neuronskih mreža. Mreže koje će biti realizovane zasnovane su i na upotrebi ortogonalnih funkcija unutar njihovih struktura. Da bi se stekao uvid u upotrebnu vrednost ovih funkcija, u ovom poglavlju će takođe biti predstavljen i dosadašnji razvoj ortogonalnih neuronskih mreža. U petom poglavlju će biti napravljen poseban osvrt na strukturu i matematički model ovog tipa mreža.

### 2.2.1 Ortogonalne neuronske mreže (ONN)

Jedan od najvažnijih zadataka pri radu sa neuronskim mrežama je adekvatan odabir aktivacionih funkcija koje će biti implementirane. Analiza uticaja standardnih aktivacionih funkcija na neuronske mreže prezentovana je u (Sibi, 2013). U cilju optimizacije mreža, konstantno se razvija veliki broj novih aktivacionih funkcija. Među njima su se posebno izdvojile ortogonalne polinomijalne funkcije. Paralelno uz razvijanje teorijske osnove ortogonalnih neuronskih mreža ispitivan je i potencijal njihove primene u različitim aplikacijama. Jedna od najvažnijih primena ortogonalnih mreža je u upravljanju nelinearnim sistemima (Nelles, 2001). Ortogonalne neuronske mreže se uspešno primenjuju i za efikasnu i preciznu aproksimaciju funkcija. U praksi su se pokazale kao pouzdane mreže sa kratkim vremenom konvergencije i karakteristikom izbegavanja lokalnih minimuma grešaka. U upotrebi je pet tipova ortogonalnih funkcija: Furijerove, Beselove, Ležandrove, kao i funkcije izražene preko Čebiševljevih polinoma prve i druge vrste. Pregled elementarnih karakteristika ovih ortogonalnih funkcija dat je u tabeli 2.1.

Tabela 2.1 Karakteristike ortogonalnih funkcija

Ortogonalne funkcije	Potpunost u graničnim tačkama	Interval definisanosti	Rekurzivna karakteristika
Furijerovi redovi	Ne postoji	[0,T]	Ne postoji
Beselove funkcije	Ne postoji	[0,1]	Postoji
Ležandrovi polinomi	Postoji	[-1,1]	Postoji
Čebiševljevi polinomi prve vrste	Postoji	[-1,1]	Postoji (jednostavna)
Čebiševljevi polinomi druge vrste	Ne postoji	(-1,1)	Postoji (kompleksna)

Iz tabele je lako uočljivo da su Ležandrovi i Čebiševljevi polinomi prve vrste optimalni izbor za razvoj ortogonalnih neuronskih mreža zbog njihovih karakteristika rekurzivnosti i kompletnosti u graničnim tačkama.

Nedostatak standardnih mreža se ogleda i u neposedovanju egzaktne relacije između broja slojeva mreže i neurona na jednoj strani, i težine problema koji se rešava na drugoj. Kod ortogonalnih mreža postoji jasna relacija - što je broj procesnih elemenata veći, greška aproksimacije je manja. Procesni elementi predstavljaju ekspanzione članove zadatih ortogonalnih funkcija. Ortogonalnost svakog procesnog elementa podrazumeva njegovu nezavisnost u odnosu na ostale procesne elemente. Generalno, ortogonalne neuronske mreže se mogu koristiti za aproksimaciju:

- 1) kontinualnih funkcija sa jednim ulazom i jednim izlazom
- 2) hibridnih funkcija sa jednim ulazom i jednim izlazom
- 3) funkcija sa više ulaza i jednim izlazom
- 4) diskretnih podataka

U nastavku će biti dat pregled značajnih radova iz oblasti ortogonalnih neuronskih mreža. U (Sher, 2001) je pokazano da *Backpropagation* (BP) neuronska mreža ima problema sa pojavom lokalnih minimuma, sporom konvergencijom i nepouzdanošću kvaliteta rezultata pri promeni broja upotrebljenih neurona. U radu su BP mreže zamenjene razvijenim ortogonalnim mrežama baziranim na po jednom izlazu i upotrebljene su u različitim aplikacijama. Takođe je prikazan način na koji se mreže mogu dalje unaprediti tako da poseduje više od jednog izlaza – upotreboom više neuronskih mreža sa jednim izlazom i njihovom sintezom u jedan sistem. Kod ortogonalnih mreža sa više izlaza osnovna karakteristika je da svaka od tih integrisanih podmreža poseduje svoje nezavisne težine koje se odvojeno treniraju i ne utiču na težine drugih podmreža. U (Chen, 2004) eksperimentalno je pokazano da aktivaciona funkcija bazirana na Ležandrovim polinomima ima manju grešku aproksimacije od aproksimacije izvršene pomoću hiperbolične tangens funkcije. U radu je definisana numerička metoda za određivanje težina ortogonalnih neuronskih mreža prilikom aproksimacije nepoznatih funkcija. Pokazano je da je za izračunavanje  $n$  težina mreže koja poseduje  $n$  procesnih elemenata potrebno samo  $n+1$  trening skupova podataka. U radu (Wang, 2009) projektovan je hibridni adaptivni kontroler baziran na PD regulatoru i Čebiševljevoj ortogonalnoj neuronskoj mreži. Kontroler je iskorišćen za upravljanje nelinearnim sistemom ruke robota sa  $n$  stepeni slobode. Pokazano je da uvođenje ortogonalne neuronske mreže u upravljačku logiku kontrolera poboljšava performanse upravljanja nelinearnim sistemom i pruža veću robustnost pod dejstvom

spoljašnjih poremećaja. Neuronska mreža u radu (Yang, 1996) bazirana je na Ležandrovim polinomima i poseduje težinske koeficijente samo između procesnih elemenata i izlaza mreže - usled čega se ovakav tip mreža naziva i jednoslojnim linearnim mrežama. Trening algoritam neuronske mreže iz (Yang, 1996) zasnovan je na metodi opadajućeg gradijenta. Ukupna izlazna greška ortogonalne mreže  $E$  se izračunava nakon svake iteracije trenažnog procesa, nakon čega se propagira unazad kroz mrežu s ciljem ažuriranja vrednosti težina. U radu je predložena i dinamička strategija ekspanzije koja predstavlja metodu odabira broja procesnih elemenata neuronske mreže koja podrazumeva inkrementalno dodavanje procesnih elemenata tokom treninga. Rad (Nikolić, 2016a) baziran je na upotrebi kvazi-ortogonalnih i skoro-ortogonalnih polinoma u vidu aktivacionih funkcija neuronskih mreža tipa NARX (nelinearna autoregresivna neuronska mreža sa egzogenim izlazima). Razvijena ortogonalna neuronska mreža upotrebljena je za upravljanje magnetnim levitacionim sistemom. Cilj projektovane upravljačke logike je obezbediti bolje performanse praćenja zadate trajektorije levitacionog objekta. Upravljačka logika zasnovana na ortogonalnoj neuronskoj mreži iterativno kompenzuje nelinearnosti i poremećaje nastale tokom levitacije. Takođe, proračunska brzina neuronskih mreža zasnovanih na ortogonalnim funkcijama eksperimentalno se pokazala većom u odnosu na proračunsku moć mreža zasnovanih na tradicionalnim aktivacionim funkcijama. U narednom radu (Hongwei, 2008), ONN je iskorišćena za dostizanje sinhronizacije sa haotičnim sistemima upotrebom Ležandrovih funkcija. Skrenuta je pažnja na prednost Ležandrove polinomijalne funkcije u odnosu na hiperboličnu tangens funkciju koja se ogleda u manjoj grešci aproksimacije. Lagerova ortogonalna neuronska mreža u (Long, 2012) je projektovana s ciljem modeliranja nelinearnosti pokretnog senzora struje. Upotrebom ortogonalne mreže smanjena je greška modelirane nelinearnosti čime je dobijen model visoke preciznosti sa bržim vremenom konvergencije i povećana je robustnost u odnosu na tradicionalni BP model neuronske mreže. U (Lin, 2013) predstavljena je rekurentna Lagerova ortogonalna mreža koja se pokazala boljom od klasične Lagerove ortogonalne mreže u smislu boljih performansi, veće preciznosti i robustnosti. Ova mreža je u radu iskorišćena za nelinearno upravljanje servo sistemom i iskorišćena je za simuliranje idealnog upravljačkog signala sistema. Poboljšanim upravljačkim signalom optimizovano je ponašanje sistema kada se nalazi u okviru definisanih ograničenja. U radu (Zhang, 2013) pokazano je da je Čebiševljeva ortogonalna neuronska mreža efikasnija pri realizaciji upravljačke logike na principu crne kutije. U konkretnom primeru izvršeno je modeliranje kretanja i manevriranja broda i pokazano da ovakva mreža može da se koristi i za identifikaciju nelinearnih hidrodinamičkih modela. Takođe, ortogonalna mreža se pokazala superiornijom u odnosu na tradicionalnu BP mrežu po pitanju performansi i pored toga što je

usvojeni algoritam učenja ortogonalne mreže identičan tipu učenja BP mreže. Gegenbauer-ova ortogonalna neuronska mreža projektovana je u (Zhang, 2009) korišćenjem principa polinomijalne interpolacije. Predložena je metoda određivanja težina mreže i određivanja smera njihovog kretanja, kojom se zadate težine mogu odrediti već nakon samo jedne iteracije. Svi aktivacioni pragovi ulaznih neurona su jednaki 1, a svi ostali su 0, čime je dodatno uprošćena struktura mreže. Pokazano je da primenom predstavljene metode Gegenbauer-ove ortogonalne mreže imaju sposobnost bržeg učenja uz manju grešku aproksimacije u poređenju sa tradicionalnim ortogonalnim mrežama. Takođe, ovakva mreža se pokazala kao efikasan alat pri predikciji vremenskih sekvenci, identifikaciji sistema i obradi signala.

### **2.2.2 Endokrine neuronske mreže**

Endokrine neuronske mreže su relativno novi tip mreža koji se bazira na ideji imitacije bioloških hormonalnih žlezdi. Veštački endokrini sistemi su realizovani na principima bioloških endokrinskih sistema. Hormoni imaju važnu ulogu u biološkim sistemima pošto se koriste za upravljanje biološkim procesima u živim organizmima. Veštačke žlezde se implementiraju u okviru arhitektura neuronskih mreža i omogućavaju adaptaciju mreže na promene uslova sredine. U radu (Timmis, 2009) je predstavljen adaptivni veštački neuro-endokrini sistem koji je sposoban da uči *online* i iskoristi podatke iz spoljašnje sredine da bi omogućio adaptivno ponašanje sistema. Sistem je sposoban da nauči asocijativne veze između senzorskih podataka i zabeleženih aktivnosti. Mreža je testirana na upravljanju realnog sistema robota i optimizaciji njegovih performansi tokom realizacije planiranih aktivnosti. U (Timmis, 2010) je, takođe za potrebe upravljanja robotskim sistemom, realizovana neuro-endokrina arhitektura. Mreža je predložena za realizaciju zadatka pretraživanja prostora i fizičkog sakupljanja objekata sa zemlje. Takođe, arhitektura se pokazala vrlo korisnom u složenim sistemima u okviru kojih egzistira i deluje više robota - došla je do izražaja u pogledu uspešnog planiranja trajektorija kretanja kod svakog robota ponaosob i izbegavanja potencijalnih sudara tokom kretanja i izvršavanja zadatka. Rad (Chen, 2014) fokusira se na unapređenju performansi neuronskih endokrinskih modela mreža razmatrajući međusoban uticaj između žlezdi. U poređenju sa navedenim endokrinim mrežama, u ovom radu se koncentracija hormona jedne žlezde podešava zavisno od koncentracije hormona drugih žlezdi. Teorijska analiza je pokazala da su performanse endokrinskih neuronskih mreža u najmanju ruku jednake, a najčešće i bolje u poređenju sa odgovarajućim standardnim neuronskim mrežama. U (Chen, 2014) je realizovani sistem upotrebljen za predikciju različitih vremenskih sekvenci podataka i

eksperimentalno je pokazano da pruža optimalne rezultate. Veštački endokrini kontroler razvijen je u (Sauze, 2013) za potrebe upravljanja potrošnjom energije još jednog robotskog sistema. Kontroler je zadužen da odgovori na različite zahteve, izvršava promenu aktivnosti tokom rada, sinhronizuje ponašanja sistema sa promenama u spoljašnjoj sredini i zadužen je za održavanje stabilnih unutrašnjih stanja robota. U radu je kontroler testiran na primeru autonomne jedrilice. Veštačke neuronske mreže su iskorišćene za upravljanje plovidbom i upravljanje kormilom, dok se endokrina neuronska mreža koristi za podešavanje aktuatora u zavisnosti od energetskog stanja baterija ili položaja sunca. Pokazano je da se primenom endokrine mreže može uspešno smanjiti potrošnja energije jednog složenog sistema. Veliki potencijal pokazan u navedenim radovima poslužio je kao glavna motivacija za njihovo dalje istraživanje i razvoj novih modela u ovoj doktorskoj disertaciji. U poglavljima 6,7,8 biće razvijene nove arhitekture endokrinskih mreža čija će upotrebna vrednost biti simulaciono i eksperimentalno ispitana.

### **2.2.3 Složene ortogonalno-endokrine strukture neuronskih mreža**

U potpoglavlјima 2.2.1 i 2.2.2 predstavljene su ortogonalne neuronske mreže (ONN) i endokrine neuronske mreže (ENN). Oba tipa mreža su se pokazala uspešnim modifikacijama standardnih neuronskih mreža čime su postale interesantne za dalja naučna istraživanja. Doktorska disertacija će se baviti kako pojedinačnim tipovima ovih mreža, tako i njihovom kombinacijom unutar jedne strukture. Cilj formiranja složene strukture je pokušaj da se dobre karakteristike koje pružaju ortogonalni polinomi i endokrini faktor pojedinačno, objedine unutar jednog modela. Time bi se u idealnom slučaju ostvarila bolja aproksimaciona moć i brža konvergencija mreže (što omogućava ortogonalnost), uz bolju adaptaciju i prilagođavanje mreže na spoljašnje uslove (obezbeđeno endokrinim faktorom). Ortogonalne endokrine neuronske mreže su u samom početku svoga razvoja i može se smatrati da je katedra za Automatiku na Elektronskom fakultetu u Nišu jedan od začetnika razvoja ovog tipa mreža. U (Perić, 2016) je predloženo upravljanje nelinearnim sistemima zasnovano na kvazi kliznom režimu pomoću estimatora realizovanog na bazi ortogonalne endokrine neuronske mreže. Endokrina mreža je u radu poslužila za modeliranje greške nastale pojmom poremećaja usled nelinearnosti sistema, čime je postignuta bolja preciznost u ustaljenom stanju. Za taj cilj realizovane su dve individualne ortogonalne endokrine mreže. Ortogonalnost je kod obe ostvarena implementacijom generalizovanih kvazi-ortogonalnih funkcija Ležandrovog tipa unutar odgovarajućih slojeva mreža. Za formiranje predikcione mreže u (Perić, 2016)

iskorišćena je NARX neuronska mreža (Siegelmann, 1997) kao osnova za nadogradnju. Veza između endokrinog faktora i mreže su težinski koeficijenti, čime se informacije iz spoljašnjeg okruženja direktno uvode u mrežu i obrađuju algoritmom učenja. Jednostavna struktura jednoslojne mreže doprinela je smanjenju proračunskog vremena u poređenju sa performansama nekih standardnih mreža. Predstavljeni algoritam testiran je na laboratorijskom modelu ABS sistema (*Anti-lock Braking System*) gde je kao endokrini faktor iskorišćen signal proklizavanja točka. Kao rezultat je dobijeno upravljanje sa manjom greškom u odnosu na performanse koje pružaju standardne mreže i konvencionalni kontrolери. Nedostatak razvijenog modela je povećana složenost strukture i kompleksniji algoritam treninga usled takve strukture. Ipak, ukoliko je glavni cilj poboljšanje performansi sistema, ovaj nedostatak postaje minoran.

### **3 Upotreba standardne neuronske mreže za poboljšanje performansi sistema**

U ovom poglavlju biće demonstrirana upotreba standardne neuronske mreže unutar upravljačke logike realnog sistema automatskog upravljanja. Veštačke neuronske mreže su se pokazale kao efikasan način upravljanja kako pojedinačnim tipovima sistema automatskog upravljanja, tako i velikim i složenim energetskim sistemima baziranim na sinergiji više tipova pojedinačnih sistema (Vankayala, 1993; Bretas, 2003; Haque, 2005; Wahab, 2009). Razlog za to je njihova univerzalnost i sposobnost da uspešno mogu procesirati veliki broj podataka. Inteligentno upravljanje je počelo da se koristi u okviru ovakvih sistema usled nemogućnosti konvencionalnih kontrolera da u prisustvu poremećaja uvek obezbede potrebnu robustnost sistema. Pokazano je da stabilnost i robustnost sistema mogu biti unapređene uvođenjem neuronske mreže u okviru postojeće upravljačke logike sistema. Veštačka neuronska mreža se može koristiti kao kompenzator čiji je zadatak da dovede dinamiku sistema u željena stanja (Ishiguro, 1992). Kombinacija neuronske mreže i fazi logike u formi hibridnog upravljanja se takođe može koristiti u svrhu unapredjenja performansi sistema (Precup, 2006; Kusagur, 2010). Veštačka neuronska mreža koja je upotrebljena za regulaciju brzine DC motora predstavljena je u (MadhusudhanaRao, 2009), gde je upravljačka logika neuronske mreže formirana iz dva dela: za estimaciju brzine motora i za generisanje upravljačkog signala. Drugi primer dobro realizovane neuronske mreže, koja uspešno upravlja DC motorom, predstavljen je u (Atri, 2012).

U ovom poglavlju disertacije biće iskorišćen laboratorijski model servo sistema zasnovan na upotrebi DC motora, dok će za estimaciju njegove brzine biti realizovan Luenbergerov observer stanja. Primer estimacije brzine pomoću takvog observera dat je u (Mehta, 1998), gde je korišćen nelinearni upravljački ulaz za upravljanje serijski vezanim DC motorima. Takođe, metode za upotrebu neuronskih mreža za estimaciju brzine motora predstavljene su i u (Dzung, 2005; Mouna, 2010; Rai, 2013).

Ovo poglavlje disertacije organizovano je u 5 potpoglavlja. U prvom potpoglavlju projektovan je observer stanja za potrebe realizacije eksperimenata. Primeri projektovanja observera predstavljeni su u radovima (Farhani, 2014; Yogesh, 2014). U potpoglavlju 3.2 projektovan je regulator promenljive strukture koji čini upravljačku osnovu sistema. U potpoglavlju 3.3 je eksperimentalno pokazano da upotrebljeni servo sistem poseduje ograničenja prilikom upravljanja u kliznom režimu kada su na osovini motora povezani tereti

velikih momenata inercije. Ova ograničenja direktno utiču na nezadovoljavajuće estimacije brzine pomoću observera. Problem loše estimacije brzine rešen je implementacijom neuronske mreže u upravljačku logiku sistema. Mreža je projektovana i trenirana pomoću realnih eksperimentalnih podataka u potpoglavlju 3.4. Nakon implementacije mreže unutar postojeće upravljačke logike sistema dobijena su značajna unapređenja estimiranih brzina (potpoglavlje 3.5) koja se ogledaju u uklonjenim odstupanjima estimirane brzine u ustaljenom stanju i minimizaciji estimirane greške tokom prelaznih procesa.

### 3.1 Procedura projektovanja observera stanja

Koordinate modela u prostoru stanja motora su neophodne za praktičnu implementaciju regulatora promenljive strukture. Upotrebljeni observer stanja predstavlja sistem za estimaciju tih koordinata upravljačkog objekta. Koordinate modela u prostoru stanja mogu se dobiti u bilo kom trenutku za poznate ulaze objekta. Ipak, nije moguće uvek formirati idealan model zbog delovanja nepoznatih i nemerljivih poremećaja na realan sistem. Luenbergerov model je iskorišćen za rešavanje ovog problema. Detaljan prikaz i formulacija Luenbergerovog modela može se naći u (Luenberger, 1979). Njegov matematički model se može predstaviti u formi:

$$\dot{\hat{x}}(t) = A\hat{x}(t) + Bu(t) + B_0(c(t) - \hat{c}(t)); \quad \hat{c}(t) = D\hat{x}(t), \quad (3.1)$$

gde su  $\hat{x}(t)$  i  $\hat{c}(t)$  vektori prostora stanja i izlaz observera, respektivno. Estimirana greška se definiše kao:

$$e(t) = x(t) - \hat{x}(t) \Rightarrow \dot{e}(t) = \dot{x}(t) - \dot{\hat{x}}(t). \quad (3.2)$$

Pogon upotrebljenog servo sistema proizvođača Inteco, Poljska (Internet dokument, 1) čini motor Bühler 1.13.044.236 čije su karakteristike date u (Internet dokument, 2). Moguće je zanemariti viskozno trenje i induktivnost u kolu rotora za vreme projektovanja observera pošto je korišćen motor koji poseduje malu snagu. Na osnovu toga, model u prostoru stanja se može predstaviti kao:

$$\begin{bmatrix} \dot{\theta} \\ \dot{\omega} \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & -\frac{1}{T_s} \end{bmatrix} \begin{bmatrix} \theta \\ \omega \end{bmatrix} + \begin{bmatrix} 0 \\ \frac{K_s}{T_s} \end{bmatrix} u_r(t); \quad c(t) = [1 \ 0] \begin{bmatrix} \theta \\ \omega \end{bmatrix}, \quad (3.3)$$

gde se  $K_s$  i  $T_s$  mogu izračunati iz:  $K_s = K / \beta R + K^2$  i  $T_s = RJ / \beta R + K^2$ . Vrednosti željenih parametara se mogu dobiti korišćenjem podataka iz tablice motora:  $a = 1/T_s = 10,526$  i  $b = K_s/T_s = 2273,68$ . Karakteristična jednačina modela motora može da se predstavi kao:

$$\det[SI - A] = \det \begin{bmatrix} s & 0 \\ 0 & s+a \end{bmatrix} = s(s+a) = s^2 + sa. \quad (3.4)$$

Polovi sistema su  $s_1 = 0$  i  $s_2 = -a$  (Precup, 2012). Željeni opseg polova observera je takav da će pol u nuli biti pomeren na novu poziciju  $s_1 = -20$ , dok će pol u  $-a$  biti pomeren u  $s_2 = -22a$ . Karakteristična jednačina motora sada uzima formu:  $(s+20)(s+22a)=0$ .

Matrica  $A_0$  projektovana je korišćenjem pravila:

$$\det[SI - A] = (s+20)(s+22a) = 0. \quad (3.5)$$

Poznato je da je  $A_0 = \begin{bmatrix} 0 & 1 \\ 0 & -a \end{bmatrix}$ ,  $B_0 = \begin{bmatrix} l_1 \\ l_2 \end{bmatrix}$ ,  $D = [1 \ 0]$ , pa će karakteristična jednačina

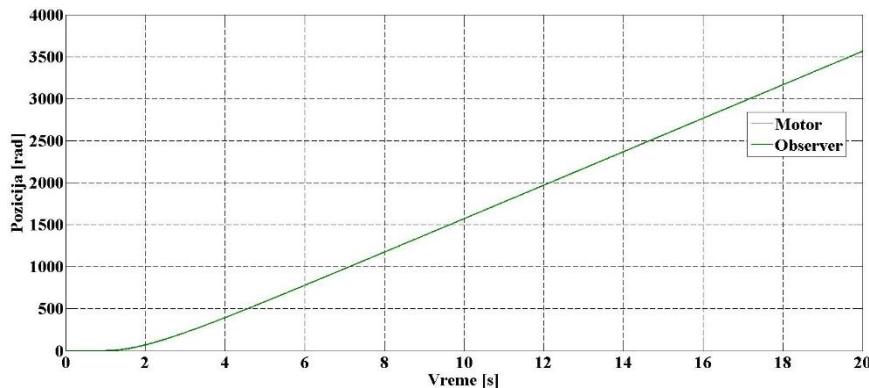
observera biti:

$$\det[SI - A] = \begin{bmatrix} s+l_1 & -1 \\ l_2 & s+a \end{bmatrix} = (s+l_1)(s+a) - (-l_2) = 0. \quad (3.6)$$

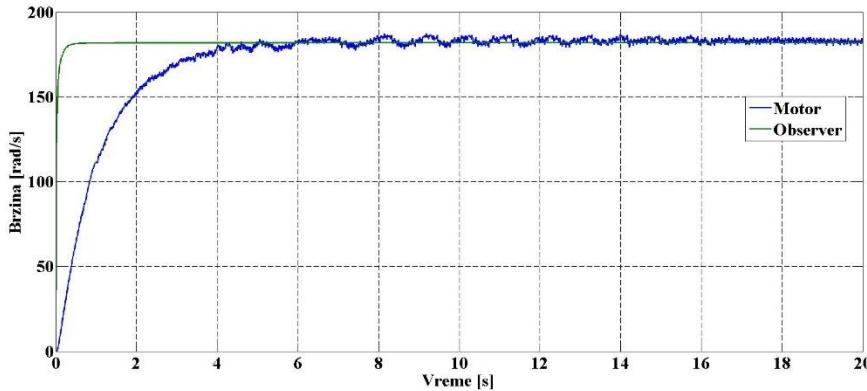
Vrednosti  $l_1 = 236$  i  $l_2 = 9,0385$  su izračunate izjednačavanjem koeficijenata iz jednačina (3.5) i (3.6). Konačni oblik projektovanog observera stanja može se predstaviti kao:

$$\begin{aligned} \dot{\hat{\theta}}(t) &= \hat{\omega}(t) + 236(\theta(t) - \hat{\theta}(t)), \\ \dot{\hat{\omega}} &= -10,56\hat{\omega}(t) + 2273,68u_r(t) + 9,0385(\theta(t) - \hat{\theta}(t)). \end{aligned} \quad (3.7)$$

Eksperimentalni rezultati dobijeni snimanjem vremenskih odziva tokom rada servo sistema prikazani su na slikama 3.1 i 3.2. Poređenje estimiranog vremenskog odziva ugaone pozicije observera i ugaone pozicije motora prikazano je na slici 3.1. Poređenje vremenskog odziva estimirane ugaone brzine observera i stvarne ugaone brzine motora prikazano je na slici 3.2.



Slika 3.1 Vremenski odzivi estimirane ugaone pozicije observera i motora



Slika 3.2 Vremenski odzivi estimirane ugaone brzine observera i motora

Na osnovu slika 3.1 i 3.2 može se zaključiti da je observer stanja dobro projektovan i da su ugaona pozicija i ugaona brzina motora estimirane sa potrebnom tačnošću.

### 3.2 Regulator promenljive strukture

Sistemi promenljive strukture su dinamički nelinearni sistemi automatskog upravljanja čija se struktura menja u zavisnosti od stanja u kome se sistem trenutno nalazi. Mogu se posmatrati kao sistemi koji se sastoje od nezavisnih struktura upravljanja i prekidačke logike, čije se upravljanje formira kao diskontinualna funkcija stanja. Usled primene prekidnog upravljanja, dinamičko ponašanje sistema promenljive strukture definisano je dinamikama njegovih struktura, čime je omogućena kombinacija korisnih osobina svake od struktura na račun dodatnog usložnjavanja regulatora. Sistem promenljive strukture može čak da poseduje i nove osobine koje nisu prisutne ni kod jedne od njegovih struktura.

Kod sistema promenljive strukture moguća su tri režima kretanja: kretanje po singularnim trajektorijama, kretanje sa preključenjima i kretanje u kliznom režimu. Od posebnog značaja je klizni režim kretanja. Ovaj optimalan režim kretanja nastaje kada se upravljanje bira tako da obezbeđuje stanju sistema da se kreće duž unapred definisane klizne hiperpovrši. Time se postižu dobre osobine sistema upravljanja promenljive strukture, kao što su redukcija reda dinamike sistema, unapred definisan karakter kretanja sistema, robustnost ili invarijantnost sistema u odnosu na dejstvo spoljašnjih poremećaja i promene parametara sistema. Iz poslednjih navedenih osobina proizilazi još jedna prednost kliznih režima, a to je eliminacija potrebe za potpunim modelom sistema. Upravljanje u kliznom režimu je tokom godina prihvaćeno kao efikasno sredstvo za projektovanje robustnih regulatora radi upravljanja složenim i nelinearnim objektima upravljanja višeg reda koji rade u neodređenim uslovima.

Kako je klizni režim kretanja dominantan i željeni oblik kretanja kod sistema promenljive strukture, kao sinonim za upravljanje promenljive strukture često se koristi upravljanje s kliznim režimom.

Termin “upravljanje promenljive strukture” (UPS) potiče, pre svega, od strukture regulatora, koja se menja pod dejstvom određene logike, a sa ciljem postizanja željene dinamike sistema. U cilju razumevanja osnovnih principa na kojima se zasniva teorija sistema promenljive strukture, biće analiziran sistem drugog reda koji je dat sledećim diferencijalnim jednačinama:

$$\begin{aligned}\dot{x}_1 &= x_2, \\ \dot{x}_2 &= -ax_2 + bu, \quad a > 0, b > b_0 > 0.\end{aligned}\tag{3.8}$$

Procedura projektovanja UPS-a sastoji se iz dva koraka. Prvi je uspostavljanje kliznog režima u okviru trajektorije sistema i podrazumeva kretanje duž klizne prave uspostavljene u konačnom vremenu. Drugi korak je zadržavanje pravca kretanja trajektorije duž klizne prave kako  $t$  teži beskonačnosti.

Ako se prekidačka funkcija prikaže kao:

$$g = cx_1 + x_2, \tag{3.9}$$

klizna prava biće definisana za  $g = 0$ . Iz toga će kretanje trajektorije sistema biti određeno kao:

$$\dot{x}_1 = -cx_1. \tag{3.10}$$

Iz (3.10) se može videti da je red jednačine kliznog režima manji od reda originalnog sistema i da je dinamika sistema određene parametrom  $c$ . To znači da dinamika procesa tokom trajanja kliznog režima neće zavisiti od originalnih dinamika sistema. Dalje, da bi se obezbedila stabilnost sistema, biće iskorišćena Ljapunova teorija stabilnosti:

$$V = \frac{1}{2} g^2. \tag{3.11}$$

Odnosno,

$$\dot{V} = g\dot{g} = g(cx_1 + x_2) = g(cx_2 - ax_2 + bu) = g(c-a)x_2 + bgu. \tag{3.12}$$

Ako se pretpostavi da izvod prekidačke funkcije  $g$  ispunjava nejednakost:

$$\left| \frac{(c-a)}{x_2} \right| < \rho(x), \tag{3.13}$$

za neke definisane funkcije  $\rho(x)$ , iz (3.12) i (3.13) se dobija sledeća nejednakost:

$$\dot{V} = g\dot{g} \leq b|g|\rho(x) + bgu. \tag{3.14}$$

Odabirom upravljačkog ulaznog signala  $u$  u obliku:

$$u = -\psi \operatorname{sign}(g), \quad \psi \geq \rho(x) + \psi_0 > 0, \quad (3.15)$$

gde je:

$$\operatorname{sgn}(g) = \begin{cases} 1, & \text{if } g > 0 \\ 0, & \text{if } g = 0, \\ -1, & \text{if } g < 0, \end{cases} \quad (3.16)$$

i zamenom (3.15) u (3.14), uslov postojanja i dostizanja stabilnosti se može izraziti kao:

$$\dot{V} \leq -b_0 \psi_0. \quad (3.17)$$

Parametar  $c$  se može izračunati ako je uslov iz (3.17) ispunjen. Na drugoj strani, ako je upravljački ulaz definisan kao kvazi-relejno upravljanje sa kliznim režimom:

$$u = \psi |x_2| \operatorname{sign}(g), \quad (3.18)$$

uslovi dostizanja i postojanja stabilnosti se izračunavaju iz:

$$\dot{V} = g \dot{g} \leq 0, \quad (3.19)$$

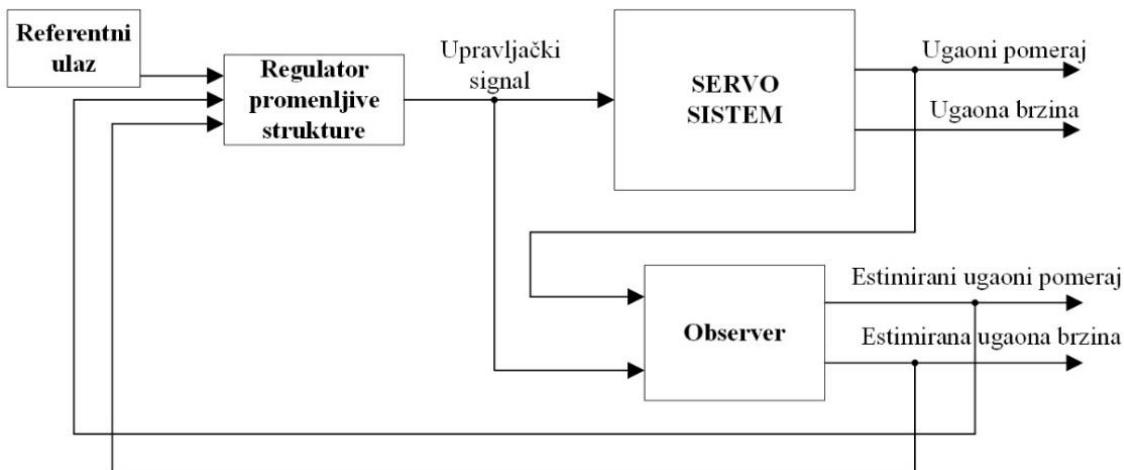
$$g(c\dot{x}_1 + \dot{x}_2) < g(cx_2 - ax_2 + bu) < g[(c-a)x_2] + bgu < 0. \quad (3.20)$$

Ako se zameni (3.18) u (3.20) dobija se sledeća nejednakost:

$$g[(c-a)x_2] + b\psi |x_2| s < 0, \quad (3.21)$$

koja je tačna za sve vrednosti  $c < a$ .

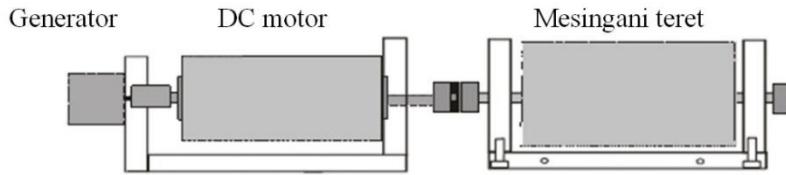
Blok dijagram servo sistema sa projektovanim observerom stanja i UPS-om prikazan je na sledećoj slici.



Slika 3.3 Blok dijagram sistema sa implementiranim observerom stanja i regulatorom promenljive strukture

### 3.3 Servo sistem sa implementiranim regulatorom promenljive strukture

Grafički prikaz servo sistema korišćenog u eksperimentima dat je na slici 3.4. Sistem uključuje mesingani teret (težine 2,030 kg i momenta inercije  $J_{bi} = 0,001105 \text{kgm}^2$ ) koji je redno vezan na osovinu DC motora.

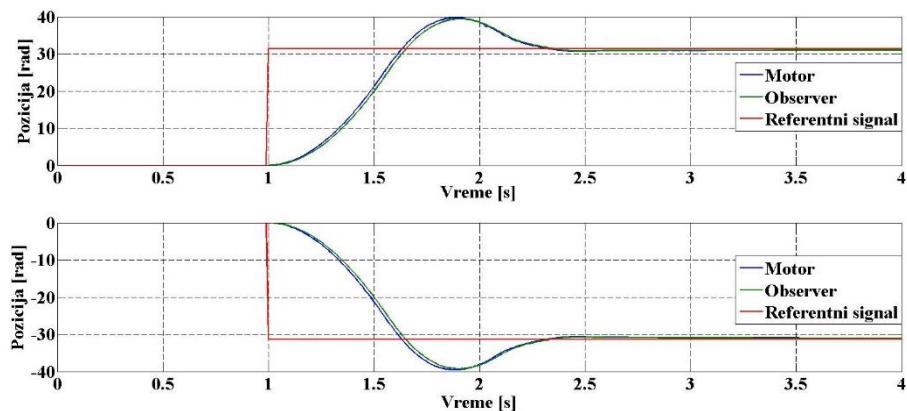


Slika 3.4 Grafički prikaz servo sistema

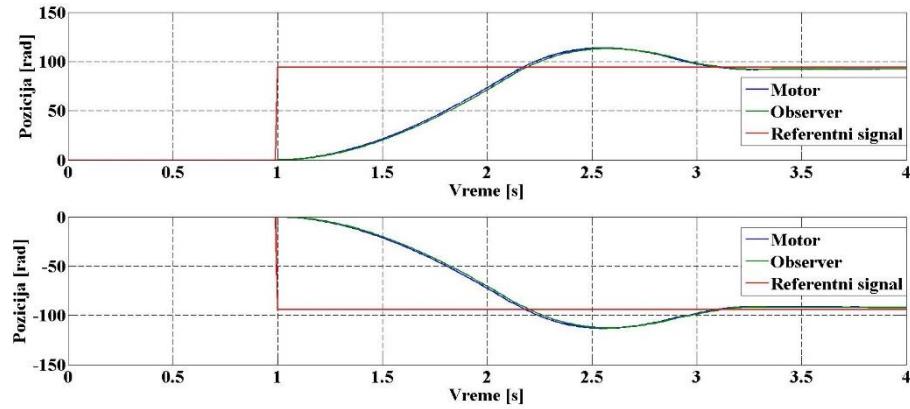
Šest odskočnih referentnih ulaznih vrednosti je iskorišćeno u eksperimentalne svrhe (Tabela 3.1). Glavni zadatak je pronaći odzive sistema za različite zadate vrednosti pozicije motora i provera kvaliteta estimacije. Eksperimentalni rezultati servo sistema sa implementiranim regulatorom promenljive strukture su prikazani na slikama 3.5 – 3.10. Sa slike 3.5, 3.6 i 3.7 može se videti da observer precizno prati ugaonu poziciju motora za svih 6 ulaznih vrednosti.

Tabela 3.1 Referentni ulazi

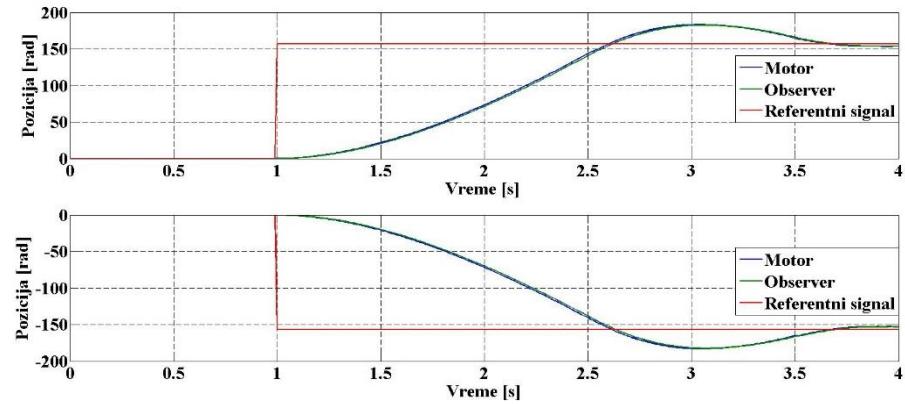
Tip signala	Definisana pozicija — Konačna vrednost ulaznog signala					
Odskočni	$-25 \cdot 2\pi$					



Slika 3.5 Estimirane ugaone pozicije observera i motora za definisane pozicije motora  $5 \cdot 2\pi$  i  $-5 \cdot 2\pi$



Slika 3.6 Estimirane ugaone pozicije observera i motora za definisane pozicije motora  $15 \cdot 2\pi$  i  $-15 \cdot 2\pi$

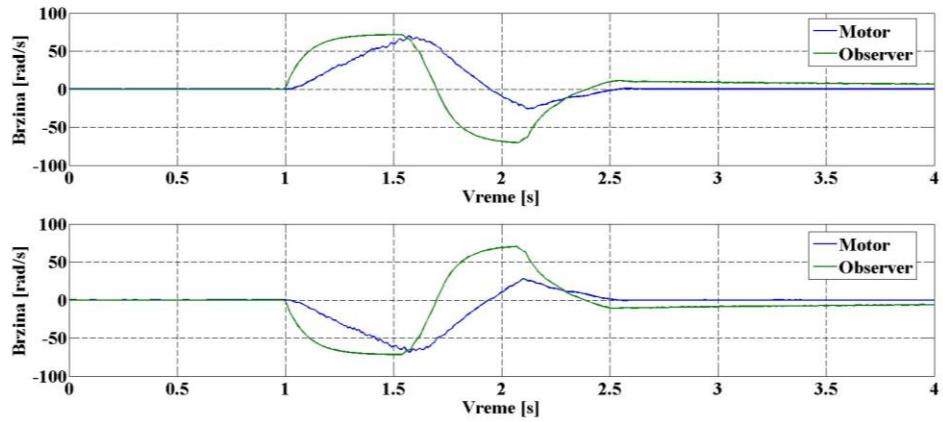


Slika 3.7 Estimirane ugaone pozicije observera i motora za definisane pozicije motora  $25 \cdot 2\pi$  i  $-25 \cdot 2\pi$

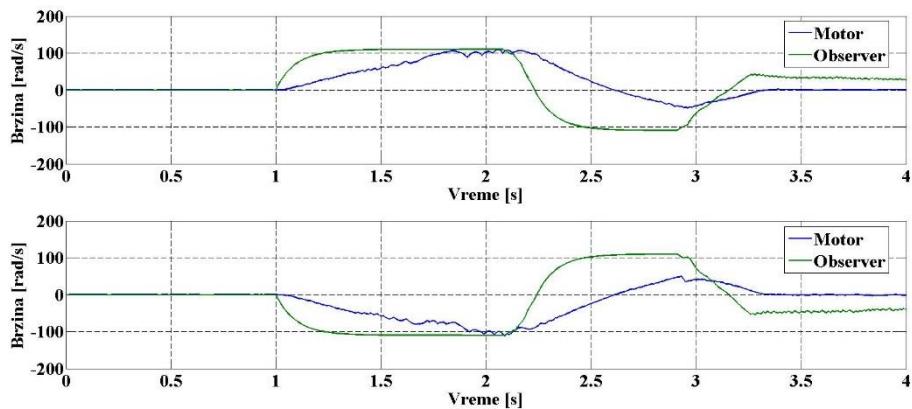
Nedostatak projektovanog observera predstavlja loša estimacija brzine i pojava odstupanja estimirane od željene pozicije osovine motora u ustaljenom stanju. Kada je željena pozicija dostignuta (Slike 3.5-3.7) brzina mora konvergirati ka 0. Analizom slika 3.8, 3.9 i 3.10 može se zaključiti da za sve ulazne vrednosti observer estimira brzine različite od 0, nakon dostizanja željenih pozicija, što je neprihvatljiv rezultat. Drugi uočljivi problem sa slikama 3.8 – 3.10 predstavljaju loše estimacione performanse tokom prelaznih procesa. Zahtevi za optimalnim prelaznim procesima (3.21) su definisani na osnovu (Chilikin, 1976). Trajanje prelaznih procesa je vremenski interval koji uključuje period startovanja, kočenja i prelazak motora sa jedne na drugu brzinu. Vreme potrebno za promenu brzine motora  $\omega_1$  na brzinu  $\omega_2$ , kada svi parametri imaju konstantne vrednosti, može se izračunati iz:

$$t_{1,2} = J \frac{\omega_2 - \omega_1}{T - T_L}, \quad (3.21)$$

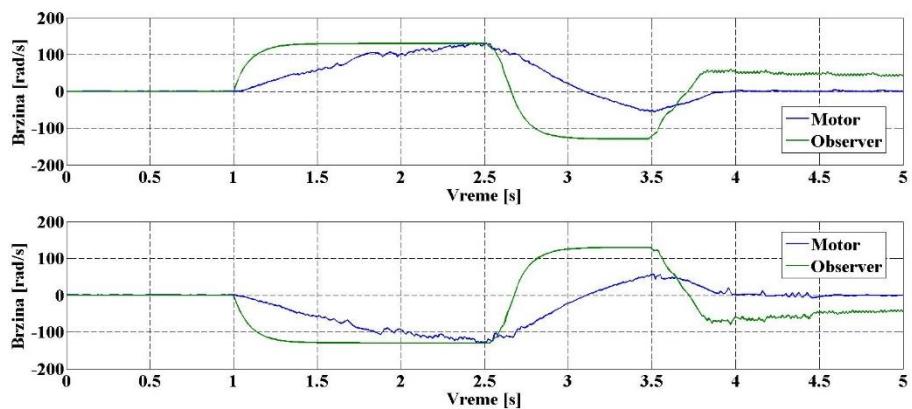
gde je  $T$  sila motora a  $T_L$  sila tereta vezanog na osovinu motora.



Slika 3.8 Estimirane ugaone brzine observera i motora  
za definisane pozicije motora  $5 \cdot 2\pi$  i  $-5 \cdot 2\pi$



Slika 3.9 Estimirane ugaone brzine observera i motora  
za definisane pozicije motora  $15 \cdot 2\pi$  i  $-15 \cdot 2\pi$



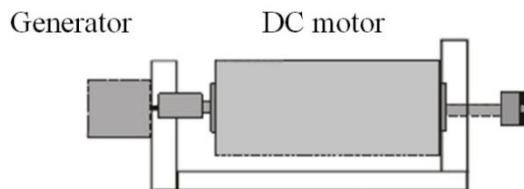
Slika 3.10 Estimirane ugaone brzine observera i motora  
za definisane pozicije motora  $25 \cdot 2\pi$  i  $-25 \cdot 2\pi$

Vremenska konstanta servo sistema  $t_{1,2}$  varira u zavisnosti od željene pozicije motora iz tabele 3.1. Relacija između momenta inercije motora  $J_{mot}$  i momenta inercije tereta  $J_{bi}$  može se izračunati kao:

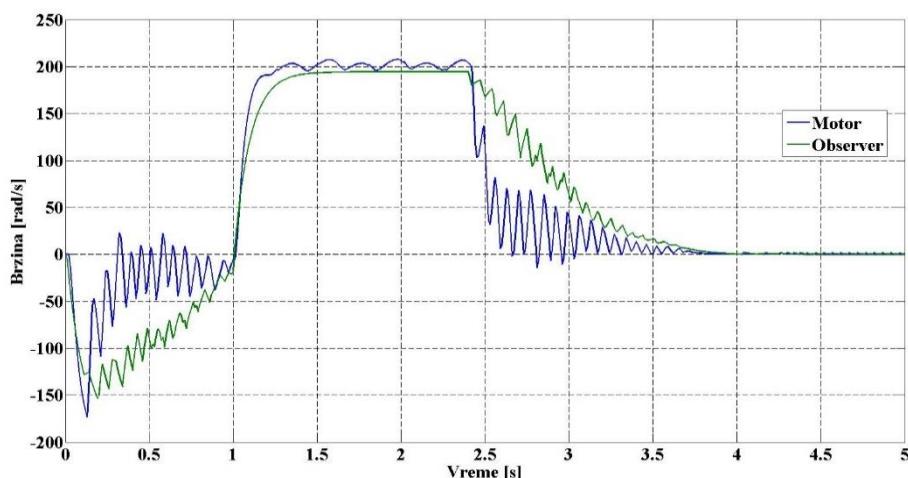
$$\frac{J_{bi}}{J_{mot}} = \frac{0.001105 \text{ kgm}^2}{0.000018 \text{ kgm}^2} \approx 61. \quad (3.22)$$

Veliki moment inercije tereta u odnosu na moment inercije motora (3.22) i nagli prelaz sa jedne brzine na drugu su dva glavna razloga za velike varijacije vremenske konstante  $t_{1,2}$  iz (3.21). Vremenska konstanta prelaznog procesa se povećava sa povećanjem tereta povezanog na osovinu motora.

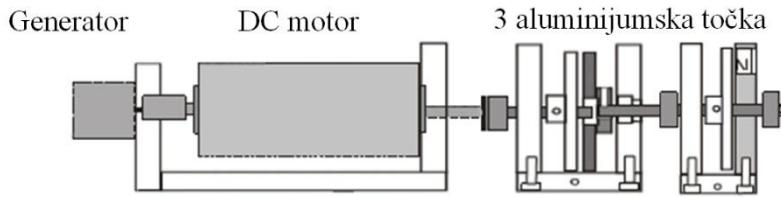
Dva eksperimenta su izvršena u cilju validacije prethodnih analiza. U njima će biti uzeti u razmatranje samo brzinski odzivi sistema. Prvi eksperiment je baziran na servo sistemu sa slike 3.11. Sistem je formiran bez ikakvog tereta povezanog na osovinu motora ( $J_l = 0$ ). UPS je uključeno u upravljačku logiku i snimljene ugaone brzine su prikazane na slici 3.12.



Slika 3.11 Servo sistem bez prikačenog tereta na osovinu motora



Slika 3.12 Estimirane brzine sistema bez priključenog tereta

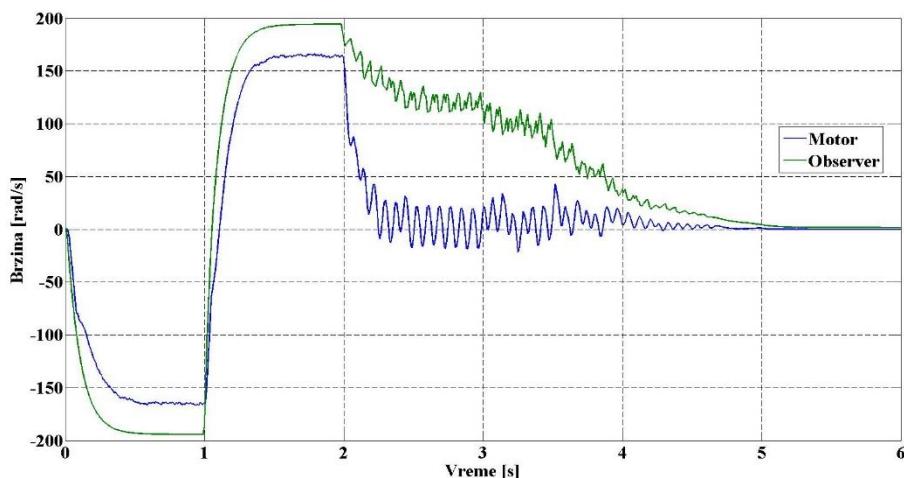


Slika 3.13 Servo sistem sa teretom u vidu tri aluminijumska točka

U drugom eksperimentu su tri aluminijumska točka vezana na osovinu motora (slika 3.13). Ukupna težina točkova je  $0.15\text{kg}$  a moment inercije  $J_{aw} = 0.00008\text{kgm}^2$ . Vremenski odziv dobijen u ovom slučaju prikazan je na slici 3.14. Vrednost referentnog ulaznog signala je za oba eksperimenta  $25 \cdot 2\pi$ . Relacija između momenta inercije DC motora ( $J_{mot}$ ) i ukupnog momenta inercije aluminijumskih točkova ( $J_{aw}$ ) je:

$$\frac{J_{aw}}{J_{mot}} = \frac{0.00008\text{kgm}^2}{0.000018\text{kgm}^2} \approx 5. \quad (3.23)$$

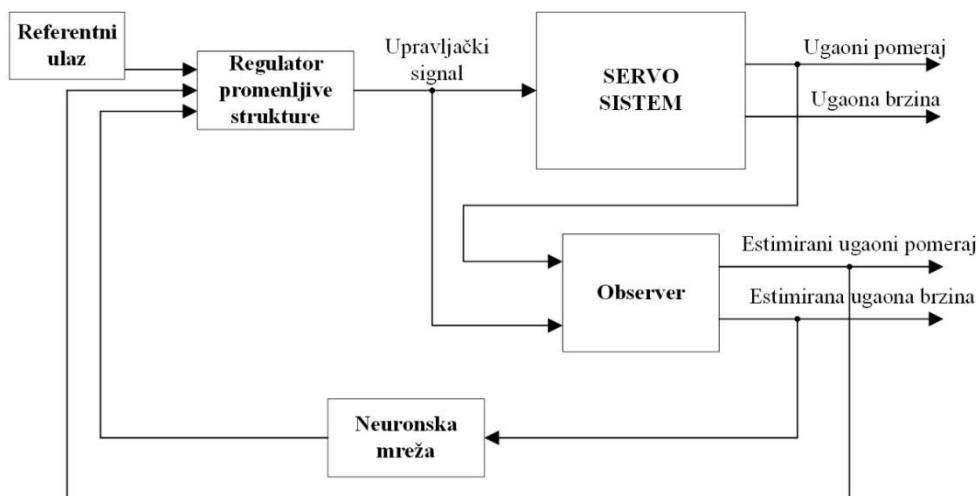
Projektovani observer estimira brzinu na zadovoljavajući način kada sistem radi bez vezanog tereta na osovinu motora. Sposobnost observera da estimira brzinu motora opada sa povećanjem momenta inercije tereta vezanog na osovinu. Odstupanje brzine je najizraženije između 2. i 4. sekunde (Slika 3.14), ali greška konvergira ka nuli nakon 4. sekunde. U sledećem poglavlju biće projektovana neuronska mreža sa ciljem unapređenja estimacionih performansi observera i celokupnog upravljanja sistemom.



Slika 3.14 Estimirane brzine sistema sa priključenim teretom

### 3.4 Projektovanje i implementacija veštačke neuronske mreže u upravljačku logiku servo sistema

Blok dijagram servo sistema sa integrисаном neuronskom mrežом priказан је на слици 3.15. Standardna *feedforward* mrežа iskorišćена је за реализацију вештачке мреже. За процес тренирања мреже употребљене су реалне вредности добијене снимањем одзива експерименталног модела током рада. Као улазни тренинг подаци искоришћене су снимљене вредности естимираније брзине помоћу обсеријера, док су за излазне тренинг податке мреже узете стварне вредности брзине мотора. Четири типа сигнала су искоришћена као реверентни улазни сигнали система: одскоčни, sinusni, trouglasti и kvadratni сигнал.



Slika 3.15 Modifikovani блок диграм управљачке логике servo система

Сваки улазни и излазни вектор који се доводи на мрежу је на почетку процеса садржавао 1000 елемената. Сваки улазно/излазни пар вектора је добијен извршењем експеримената са различитим реверентним улазним сигналима. Осамнаест различитих реверентних улазних сигналова је искоришћено у ову сврху и њихове вредности се могу видети у табели 3.2. Експерименти су извршени на систему са стандардном управљачком логиком (Слика 3.3). Укупан број елемената свих вектора је 36000, чиме је формирана потребна база тренинг података.

Након извршеног тrenažnog процеса добијени су лоши резултати који су се огледали у великој средњеквадратној грешци тренираније мреже и великом прорачунском времену. Разлог за лоше резултате је гломазна тренинг база података коју мрежа није успела успешно да обради. Problem је решен применом procedure redukcije података на тај начин што је смањен број елемената

unutar svakog vektora. Svaki novoformirani vektor sadržao je 100 elementa umesto 1000, što je učinilo bazu podataka značajno manjom i efikasnijom za procesiranje.

Tabela 3.2 Referentni ulazi

Tip signala	$I_{S_{fv}}$ — Konačna vrednost referentnog ulaznog signala (zadata pozicija)					
ODSKOČNI	$1 \cdot 2\pi$	$5 \cdot 2\pi$	$10 \cdot 2\pi$	$15 \cdot 2\pi$	$20 \cdot 2\pi$	$25 \cdot 2\pi$
	$-1 \cdot 2\pi$	$-5 \cdot 2\pi$	$-10 \cdot 2\pi$	$-15 \cdot 2\pi$	$-20 \cdot 2\pi$	$-25 \cdot 2\pi$
SINUSNI	$25 \cdot 2\pi$	$-25 \cdot 2\pi$				
TROUGLASTI	$25 \cdot 2\pi$	$-25 \cdot 2\pi$				
KVADRATNI	$25 \cdot 2\pi$	$-25 \cdot 2\pi$				

Da bi neuronska mreža bila upotrebljiva u okviru postojeće upravljačke logike, potrebno ju je projektovati sa jednim ulazom i jednim izlazom. Razlog za to je struktura eksperimentalnog okruženja servo sistema koje za procesiranje podataka u realnom vremenu zahteva ulazno/izlazne vektore dimenzija  $m \times 1$ . Konačan oblik jedinstvenog ulaznog vektora dođen je spajanjem svih redukovanih ulaznih vektora, tako što su nakon zadnje vrednosti jednog, upisivane redom vrednosti narednog vektora. Ista procedura ponovljena je i za formiranje jedinstvenog izlaznog vektora, naravno uz spajanje odgovarajućih pojedinačnih izlaznih vektora. Broj trening iteracija, tip trenažnog procesa i broj neurona u skrivenom sloju određen je eksperimentalno. Za aktivacionu funkciju neuronske mreže odabrana je standardna hiperbolična sigmoidna aktivaciona funkcija (tansig). Osamnaest različitih tipova treninga iskorišćeno je za inicijalnu fazu testiranja. Dobijeni trening rezultati prikazani su u tabeli 3.3.

Polja iz tabele 3.3 koja su označena sa „x“ označavaju nezadovoljavajuće trening rezultate usled divergencije performansi, ekstremno loših rezultata ili suviše spore konvergencije performansi mreže. Ti podaci neće biti analizirani. Svi tipovi treninga iz tabele su standardni tipovi treninga integrirani u Matlab softverski paket i detaljno su predstavljeni u (Demuth, 2013). Parametar odlučivanja prilikom odabira trening procesa je ukupna greška koja je napravljena tokom treninga, označena kao kategorija performansi u tabeli 3.3. Idealan rezultat bi bio onaj gde se kao indeks performanse dobije vrednost 0. Iz tabele 3.3 je odabранo 7 najboljih tipova treninga na osnovu dobijenih performansi. Oni su dalje detaljno analizirani, opsezi broja neurona koji potencijalno mogu da daju bolje rezultate su eksperimentalno odabrani, i izvršene su nove trening procedure. Rezultati ovih dodatnih analiza dati su u tabeli 3.4.

Tabela 3.3 Inicijalna faza treniranja/testiranja

Broj neurona:	5	10	20	50	100	200	300
Broj iteracija:	1000						
Trening tip	Performanse						
trainb	x	x	x	x	x	x	x
trainbfg	2030,81	2121,26	2045,74	2539,57	3610,38	8231	13293,6
trainbr	2,35 *10^6	2,33 *10^6	2,02 *10^6	1,87 *10^6	1,71 *10^6	x	x
trainbuwb	x	x	x	x	x	x	x
trainc	x	10013,1	11378,3	8266,13	x	x	x
traincgb	2144	2140,42	2031,82	2054,61	1903,4	1744,45	3280,25
traincfg	2332,31	2166,54	1969,6	2009,24	2447,35	3909,72	x
traincgp	2048,78	2262,55	2020,01	2069,71	1937,8	2959	2698,41
traingd	2,7 *10^44	2,7 *10^48	2,17 *10^51	2,2 *10^57	x	x	x
traingda	2486,53	2935,52	4174,84	7837,16	16314,6	x	x
traingdm	3,66 *10^32	3,01 *10^36	1,17 *10^42	4,7 *10^47	x	x	x
traingdx	2278,56	2161,79	15606,5	3500,76	8335,5	12280,2	x
trainlm	2300,2	2114,77	2111,07	1946,85	1578,29	992,037	946,069
trainoss	2266,92	2240,2	1964,89	2368,82	2470,58	4092,24	x
trainr	x	4782,69	5338,76	6632,04	x	x	x
trainrp	2191,89	2179,37	2124,28	1929,01	2068,66	1678,16	2074,26
trains	x	x	x	x	x	x	x
trainscg	2100,9	2102,76	2015,77	2185,61	2093,41	1748,67	2061,14

Tabela 3.4 Finalna faza treniranja/testiranja

Trening tip	trainscg	trainrp	trainlm	traingdx	traincgp	traincgb	trainbfg
Broj neurona	30	40	600	7	30	15	3
Performanse	2106,3	2078,4	617,1	2549,7	2594,4	2101,1	2342,9
Broj neurona	40	60	700	12	40	30	8
Performanse	1995,1	2346,8	549,3	2151,6	2118,3	2005,2	2399,2
Broj neurona	125	150	800	16	70	40	15
Performanse	2277,7	1914,4	429,5	2309	2721,1	2108,6	2064
Broj neurona	150	170	900	18	80	60	20
Performanse	1733,7	1886,3	665,6	2282,6	2176,7	1884,1	2148,9
Broj neurona	170	190	1000	*	90	80	100
Performanse	2398,7	1805,1	572	*	2034,6	1899	1892,9
Broj neurona	190	230	1100	*	*	120	*
Performanse	2375,4	1715,1	534,3	*	*	2314,2	*
Broj neurona	*	350	1200	*	*	150	*
Performanse	*	1688,2	339,4	*	*	1947,7	*

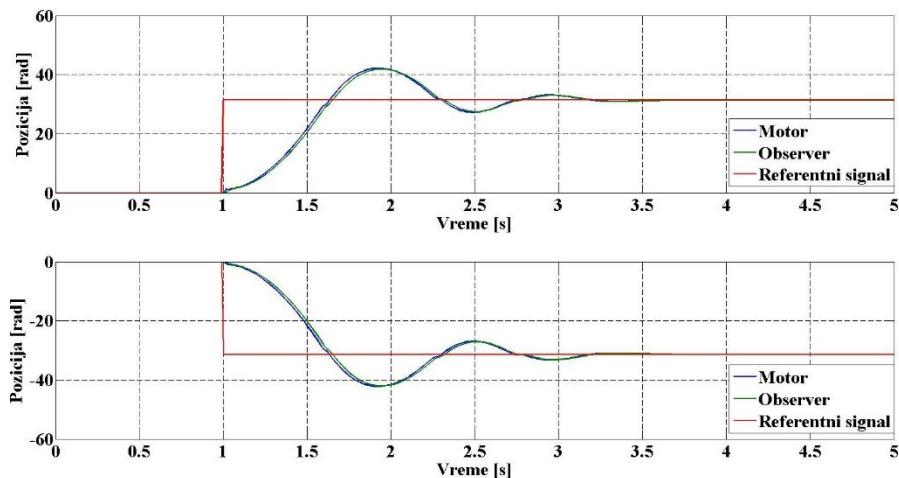
Iz tabele 3.4 može se zaključiti da trening proces *trainlm* pruža najbolje rezultate učenja mreže. *Trainlm* je trening funkcija mreže koja ažurira težine i aktivacione pragove na osnovu

Levenberg-Marquardt optimizacione metode. Smatra se da je to jedan od najbržih *backpropagation* algoritama. Nedostatak ove funkcije je potreba za većom memorijom računara u odnosu na ostale algoritme. Na kraju faze testiranja i na osnovu tabela 3.3 i 3.4, odabранo je 1200 neurona u skrivenom sloju i *trainlm* trening procedura za proces učenja mreže.

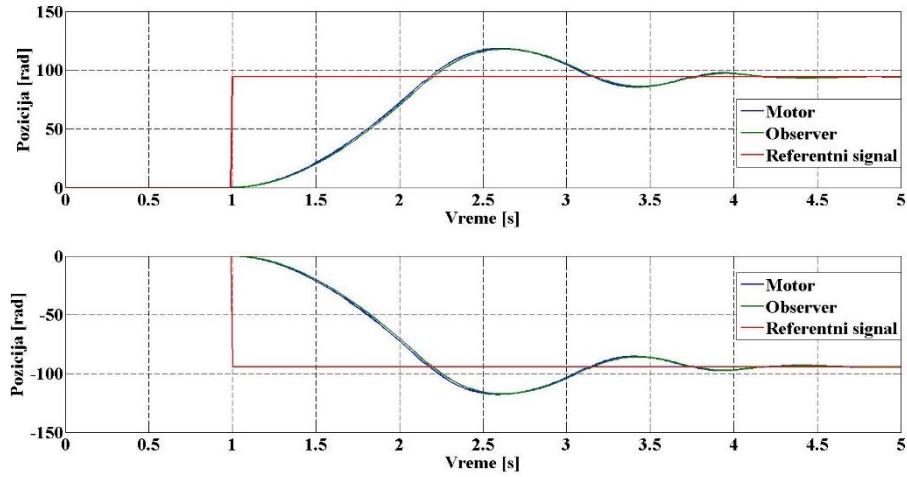
### 3.5 Eksperimentalni rezultati i analiza rada servo sistema sa implementiranom *feedforward* neuronskom mrežom

Na slikama 3.16-3.21 predstavljeni su vremenski odzivi eksperimenata na modifikovanom servo sistemu sa slike 3.15. Šest odskočnih referentnih ulaza prikazanih u tabeli 3.1 je upotrebljeno i odzvi sistema (za svaki ulazni signal pojedinačno) su snimljeni. Evaluacija performansi je u ovoj drugoj fazi testiranja bila bazirana na četiri parametra: tačnosti estimirane ugaone pozicije, stepenu odstupanja estimiranog odziva u ustaljenom stanju, brzini prelaznog procesa i kvalitetu estimirane ugaone brzine za vreme prelaznog procesa.

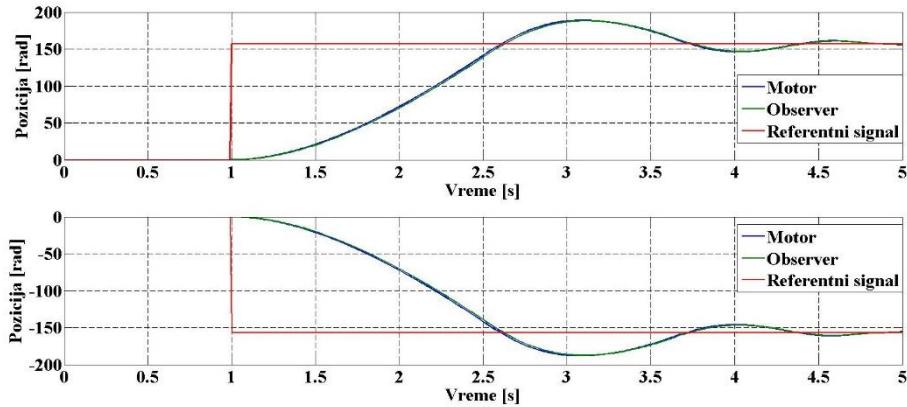
Na osnovu dobijenih rezultata može se zaključiti da je observer zadržao kvalitet estimacije ugaone pozicije za sve ulazne signale, što se može videti na slikama 3.16, 3.17 i 3.18. Slike 3.19, 3.20 i 3.21 prikazuju poređenja estimiranih ugaonih brzina iz observera i motora. Estimacije brzina observera u ustaljenom stanju je unapređena u odnosu na odzive sistema na slikama 3.8, 3.9 i 3.10. Pojava odstupanja estimiranog signala u ustaljenom stanju je rešena i greške za sve referentne ulazne signale iz tabele 3.1 su uklonjene.



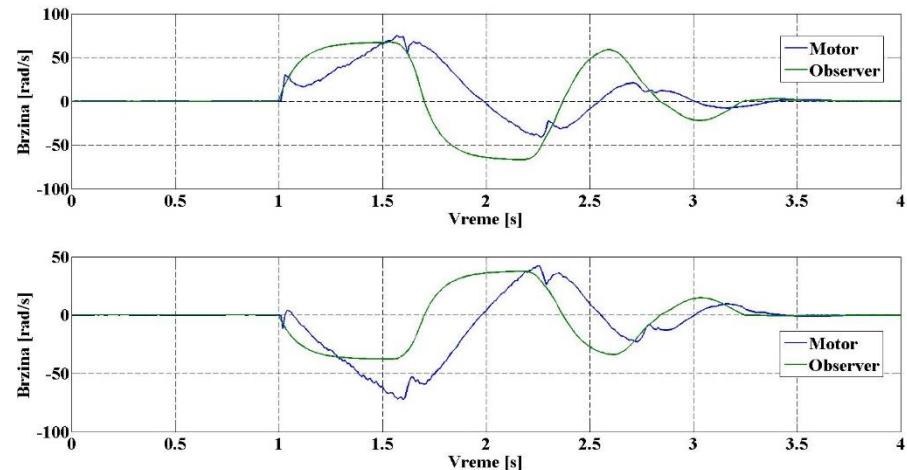
Slika 3.16 Estimirane ugaone pozicije observera i motora za definisane pozicije motora  $5 \cdot 2\pi$  i  $-5 \cdot 2\pi$ , nakon implementacije neuronske mreže



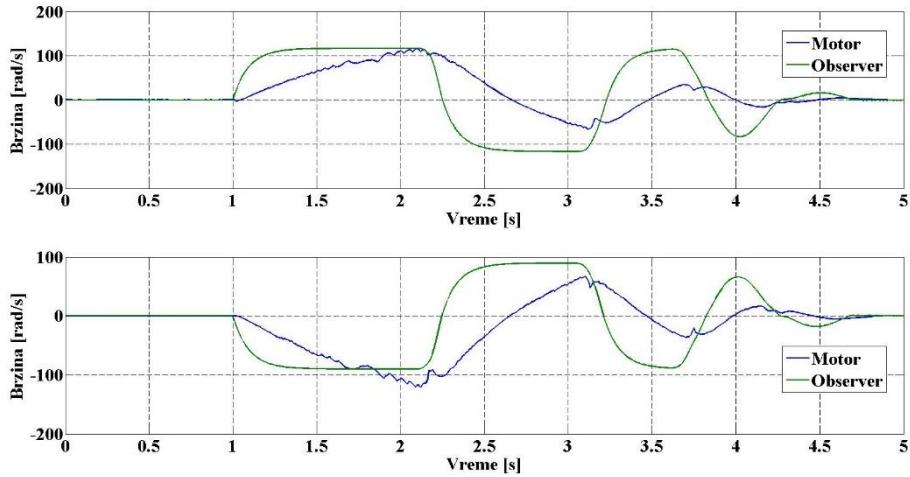
Slika 3.17 Estimirane ugaone pozicije observera i motora za definisane pozicije motora  $15 \cdot 2\pi$  i  $-15 \cdot 2\pi$ , nakon implementacije neuronske mreže



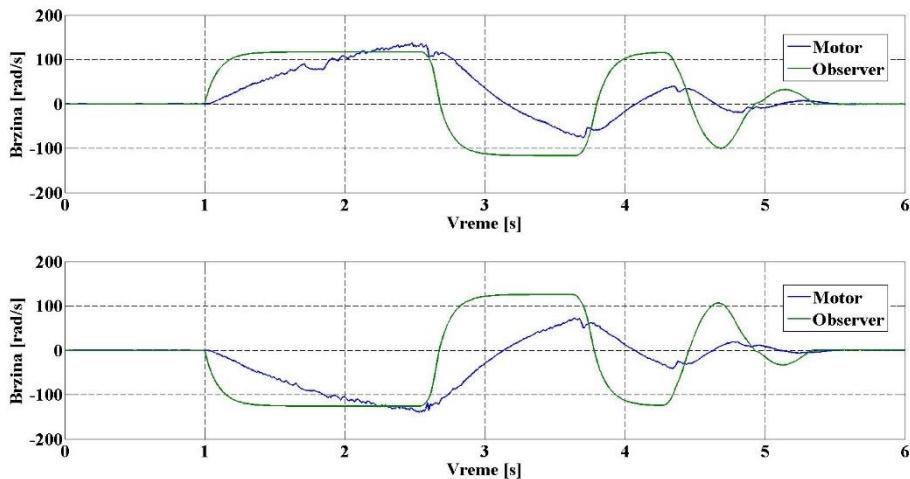
Slika 3.18 Estimirane ugaone pozicije observera i motora za definisane pozicije motora  $25 \cdot 2\pi$  i  $-25 \cdot 2\pi$ , nakon implementacije neuronske mreže



Slika 3.19 Estimirane ugaone brzine observera i motora za definisane pozicije motora  $5 \cdot 2\pi$  i  $-5 \cdot 2\pi$ , nakon implementacije neuronske mreže



Slika 3.20 Estimirane ugaone brzine observera i motora za definisane pozicije motora  $15 \cdot 2\pi$  i  $-15 \cdot 2\pi$ , nakon implementacije neuronske mreže



Slika 3.21 Estimirane ugaone brzine observera i motora za definisane pozicije motora  $25 \cdot 2\pi$  i  $-25 \cdot 2\pi$ , nakon implementacije neuronske mreže

Tabela 3.5 formirana je na osnovu analiza prelaznih procesa pre i nakon implementacije neuronske mreže. Vreme trajanja prelaznih procesa servo sistema označeno je sa  $t_{tp\_ss}$ , vreme trajanja prelaznih procesa modifikovanog servo sistema označeno je sa  $t_{tp\_ss+nn}$ ,  $t_i$  predstavlja povećano vreme trajanja prelaznih procesa servo sistema nakon ugrađene mreže,  $Is_{fv}$  definiše konačne vrednosti referentnih ulaznih signala i  $I_t(\%)$  predstavlja povećano vreme trajanja eksperimenta sistema sa ugrađenom mrežom u odnosu na startni sistem bez mreže, u procentima. Može se zaključiti da se sve brzine prelaznih procesa, nakon implementacije mreže, smanjuju u opsegu od 25,6% do 46,2%. To implicira da odzivi sistema postaju sporiji nakon integrisanja mreže u upravljačku logiku. Uticaj na brzinu performansi se može karakterisati kao

nedostatak ukoliko su izražene potrebe za dobijanjem podjednako brzih odziva kao u slučajevima bez implementirane neuronske mreže. Prvenstveni cilj u slučaju ovog eksperimentalnog rada je povećanje preciznosti estimiranih signala, pa će uticaj mreže na brzinu odziva biti zanemaren.

Tabela 3.5 Vreme trajanja prelaznih procesa servo sistema

$Is_{fv}$	$t_{tp\_ss}$	$t_{tp\_ss+nn}$	$t_i$	$I_t(\%)$
$-25 \cdot 2\pi$	4,45s	5,59s	1,14s	<b>25,6</b>
$-15 \cdot 2\pi$	3,35s	4,90s	1,55s	<b>46,2</b>
$-5 \cdot 2\pi$	2,55s	3,55s	1,00s	<b>39,2</b>
$5 \cdot 2\pi$	2,60s	3,71s	1,11s	<b>42,7</b>
$15 \cdot 2\pi$	3,40s	4,91s	1,51s	<b>44,4</b>
$25 \cdot 2\pi$	4,01s	5,56s	1,55s	<b>38,6</b>

Tabela 3.6 predstavlja poređenje kvaliteta estimacija observera pre i nakon implementacije neuronske mreže.  $Err_{ss}$  i  $Err_{ss+nn}$  predstavljaju absolutne greške sistema bez i sa mrežom, respektivno. Svaka greška je formirana kao absolutna vrednost razlike brzine estimirane observerom i stvarne brzine motora. Treba naglasiti da su analizirani samo delovi koji uključuju prelazne procese. Iz tabele je uočljivo da su u najvećoj meri absolutne greške sistema, bez implementirane mreže, manje. Ipak, treba imati u vidu da ograničavanje na prelazne procese ne daje pravi uvid o ukupnim estimacionim greškama koje obuhvataju i ustaljena stanja procesa (Slike 3.8-3.10). U tom slučaju, za utvrđenu celokupnu absolutnu grešku na snimljenom odzivu, bi svakako  $Err_{ss}$  standardnog sistema višestruko bila veća od  $Err_{ss+nn}$ . Dalje,  $Erpr_{ss}$  i  $Erpr_{ss+nn}$  predstavljaju estimirane greške u sekundi za standardnu upravljačku logiku i logiku sa neuronskom mrežom respektivno, E.Q.I. predstavlja procentualno unapređenje kvaliteta estimacije observera – poređenje rezultata pre i nakon implementacije neuronske mreže. Iz tabele 3.6 može se zaključiti da je preciznost estimacije poboljšana u 5 od 6 realizovanih eksperimenata (kolona  $I_{OE}(\%)$ ). Neuronska mreža poboljšava performanse observera za sve negativne vrednosti ulaznih signala. Za pozitivne vrednosti ulaznih signala lošiji rezultati se javljaju u slučaju kada se za konačnu vrednost ulaznog signala odabere  $15 \cdot 2\pi$ . Za sve druge eksperimentalne slučajeve iz tabele 3.6 zabeležena su poboljšanja estimacije observera nakon implementacije neuronske mreže u opsegu od 2,2% do 28,2%. Mreža kompenzuje greške estimiranih odziva sistema koje se javljaju kao rezultat dejstva tereta sa velikim momentima inercije na osovinu motora, kada je za upravljanje sistemom zadužen

regulator promenljive strukture. Generalno, ovakva inteligentna upravljačka logika bi se trebala koristiti kada su zahtevi od upravljačkog sistema pouzdanija i preciznija estimacija brzine motora pomoću observera. Nedostatak upravljačke logike modifikovanog servo sistema je povećano trajanje odziva sistema tokom prelaznih procesa. Ukoliko je glavni zahtev upravljačkog sistema upravo brzina odziva, onda je potrebno izbegavati implementaciju slične *feedforward* neuronske mreže unutar upravljačke strukture.

Tabela 3.6 Komparacija eksperimentalnih rezultata pre i nakon implementacije neuronske mreže

$IS_{fv}$	$Err_{ss}$	$Err_{ss+nn}$	$Erpr_{ss}$	$Erpr_{ss+nn}$	$E.Q.I.$	$I_{OE}(\%)$
$-25 \cdot 2\pi$	$23,666 \cdot 10^3$	$28,655 \cdot 10^3$	$5,318 \cdot 10^3$	$5,126 \cdot 10^3$	<b>DA</b>	<b>3,6</b>
$-15 \cdot 2\pi$	$13,826 \cdot 10^3$	$16,990 \cdot 10^3$	$4,127 \cdot 10^3$	$3,467 \cdot 10^3$	<b>DA</b>	<b>16,0</b>
$-5 \cdot 2\pi$	$4,937 \cdot 10^3$	$4,935 \cdot 10^3$	$1,936 \cdot 10^3$	$1,390 \cdot 10^3$	<b>DA</b>	<b>28,2</b>
$5 \cdot 2\pi$	$5,128 \cdot 10^3$	$7,151 \cdot 10^3$	$1,972 \cdot 10^3$	$1,927 \cdot 10^3$	<b>DA</b>	<b>2,2</b>
$15 \cdot 2\pi$	$13,566 \cdot 10^3$	$22,459 \cdot 10^3$	$3,990 \cdot 10^3$	$4,574 \cdot 10^3$	<b>NE</b>	<b>-12,8</b>
$25 \cdot 2\pi$	$19,982 \cdot 10^3$	$26,938 \cdot 10^3$	$4,983 \cdot 10^3$	$4,844 \cdot 10^3$	<b>DA</b>	<b>2,8</b>

## **4 Metoda za selekciju i optimizaciju ulaznih parametara veštačke neuronske mreže**

U ovom poglavlju biće predstavljena nova metoda za optimizaciju i preprocesiranje baza podataka koje će se koristiti za obuku veštačke neuronske mreže. Metoda je zamišljena tako da bude primenljiva na različite tipove mreža i trenažnih procesa. Za simulacionu proveru predložene metode biće iskorišćeno istraživanje u kome je cilj predviđanje vrednosti kursa jedne novčane valute u odnosu na drugu valutu. Istraživanje je zasnovano na bazi podataka koja sadrži 140 različitih parametara za dva ekonomskog sistema. Ekonomija jedne zemlje se može smatrati veoma kompleksnim sistemom na koje utiče veliki broj parametara. Neophodna je detaljna i iscrpna analiza da bi se utvrdile zavisnosti i korelacije koje važe u takvom sistemu. Danas se pored velikog broja tradicionalnih matematičkih metoda koje obrađuju podatke iz oblasti ekonomije sve više koriste i neuronske mreže kao alat za obradu tih podataka. Osnovne karakteristike neuronskih mreža koje se koriste u ovakvim sistemima prikazane su u potpoglavlju 4.1. Cilj naučnog istraživanja obuhvaćenog ovim poglavljem je prezentovanje novog načina optimizacije i odabira parametara koji će se koristiti za obuku neuronske mreže i koji predstavlja efikasnu metodu za preprocesiranje velikih baza podataka (potpoglavlja 4.2 i 4.3). U potpoglavlju 4.4 utvrđene su međusobne zavisnosti redukovanih parametara i formirani ulazni vektori neuronske mreže. U potpoglavlju 4.5 formirani su ulazno/izlazni vektori iskorišćeni za trenažni proces projektovane *feedforward* neuronske mreže. Konačno, prediktioni simulacioni rezultati mreže detaljno su prezentovani i analizirani.

### **4.1 Upotreba veštačkih neuronskih mreža u ekonomskim sistemima**

Prediktivne osobine neuronskih mreža su glavni razlog za njihovo veliko prisustvo u ekonomiji (Mileris, 2011; Sakalas, 2011). Dve glavne oblasti upotrebe veštačkih mreža u ekonomskim sistemima su predikcija cena akcija na tržištu i predviđanje kursa novčanih valuta na dnevnoj ili nedeljnoj bazi. *Random Walk* matematički model je u prošlosti služio kao pogodan metod za predikciju vrednosti novčanih valuta (Tyree, 1995). U (Palombizio, 2012) autori su iskoristili realne vrednosti 8 ekonomskih indikatora za predikciju dnevnog kursa novčane valute Kanadski Dolar. Pojedini autori su za potrebe predikcije ekonomskih parametara razvijali adaptivne (Yu, 2005; Dobrescu, 2006) i rekurentne tipove neuronskih

mreža (Tenti, 1996). Generalno, dva tipa podataka se mogu iskoristiti za predikciju vrednosti novčanih valuta. Prvi tip su istorijske vrednosti valute za definisanu vremensku sekvencu u prošlosti. U tom slučaju se za ulaze neuronske mreže koriste vektori koji se sastoje od podataka sa tačnim datumima kada je praćena vrednost valute, dok se za izlaze mreže koriste stvarne vrednosti valute za te odgovarajuće datume (Philip, 2011). Drugi tip podataka koji se može iskoristiti za ulaze mreže su ekonomski indikatori. Ovo je mnogo kompleksnije rešenje pošto od ogromnog broja različitih parametara koji utiču na ekonomski sistem (a samim tim i na vrednost novčane valute) treba izabrati samo nekoliko parametara. Ipak, i ako se izaberu najvažniji parametri za ulazne promenljive neuronske mreže, nema garancija da će mreža imati potrebnu tačnost predikcije nakon obuke. To čini predikciju i čitav proces obrade informacija kompleksnim i osetljivim i predstavlja izazov za naučna istraživanja.

## **4.2 Ekonomski parametri i PCA (Principal Component Analysis) metoda**

Neuronska mreža će u ovom istraživanju biti iskorišćena za predikciju vrednosti kursa Ruske novčane valute rublje u odnosu na Američki dolar. Cilj istraživanja je fokusiranje na relevantnim indikatorima oba ekonomskog sistema (ruskom i američkom). Zašto je potrebno uzeti oba sistema u razmatranje? Uzmimo za primer da su samo parametri Ruske Federacije iskorišćeni za određivanje vrednosti kursa valute. To će značiti da ukoliko Rusija dostigne rast BDP-a od 2% u nekom trenutku, zavisni ekonomski indikatori će takođe biti ispraćeni uvećanjem - direktno utičući u nekoj meri na jačanju kursa njihove valute u u odnosu na Dolar. Nedostatak ove metode se može uvideti odmah - bazirana je na praćenju parametara jednog ekonomskog sistema, bez razmatranja ekonomskih indikatora drugog sistema. Tačnije, vrednost Rublje predviđena je bez znanja o eventualnim ekonomskim promenama u Americi koje bi uticale na međusobnu zavisnost dve valute. Ispravno bi bilo koristiti jedan ekonomski sistem za ulazne parametre samo ukoliko se smatra da su u drugom sistemu parametri konstantni za taj vremenski period. Cilj istraživanja u ovom poglavlju disertacije je predstavljanje metode odabira ulaznih parametara neuronske mreže i koja će uzeti u razmatranje oba ekonomskog sistema i njihove međusobne zavisnosti koje utiču na vrednost novčanih valuta.

Za inicijalnu bazu podataka uzete su vrednosti 70 ekonomskih parametara grupisanih u 6 kategorija: Glavni ekonomski indikatori (15 parametara), Realni ekonomski indikatori (14 parametara), Eksterni indikatori (2 parametra), Finansijski indikatori (19 parametara), Državni finansijski indikatori (5 parametara) i Tržišni indikatori (15 parametara). Informacije za svaki od ovih parametara su preuzete sa relevantnih sajtova (Internet dokument, 3; Internet dokument,

4; Internet dokument, 5). Lista parametara po navedenim kategorijama data je u tabeli 4.1. Parametri ovih 6 kategorija su iskorišćeni za analizu američkog i ruskog ekonomskog tržišta. Ovo je omogućilo direktno poređenje parametara dva ekonomski sistema i razvoj međusobnih zavisnosti i relacija. Sve vrednosti su uzimane na mesečnoj bazi, u vremenskom intervalu 2008 – 2012. godina. Formirana baza podataka sadrži 140 ulaznih promenljivih (po 70 za svaki sistem) i svaki od njih se dinamički i nelinarno menja u odnosu na vremensku bazu. Sledeći zadatak nakon inicijalne selekcije ulaznih parametara i formiranja baze podataka je njena optimizacija i redukcija. Cilj optimizacionog procesa je redukcija inicijalnog broja ulaznih parametara unutar svake navedene kategorije i dobijanje jediničnih vektora za svaku kategoriju ponaosob. Novi vektori predstavljajuće kombinaciju odabralih početnih vektora i bazirani su na međusobnoj zavisnosti i težinskim koeficijentima koji će biti predstavljeni u daljem radu.

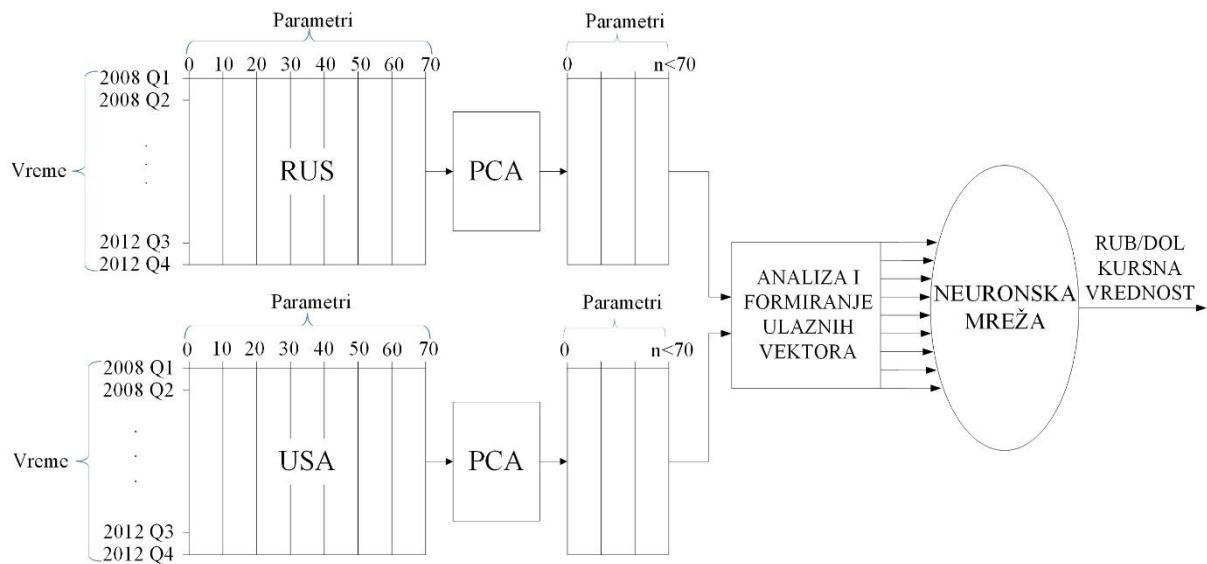
PCA (*Principal Component Analysis*) predstavlja metodu obrade podataka koja će biti iskorišćena u ovom istraživanju. PCA je široko primenjena matematička metoda koja ima veliku upotrebnu vrednost i može se iskoristiti za procesiranje velikih baza podataka, obradu signala, analizu statističkih podataka, prepoznavanje lica, identifikaciju skupova podataka, analizu pokreta, klasterizaciju podataka, redukciju dimenzija vektora i matrica podataka (Jeong, 2009). Glavni cilj redukcije dimenzija je upotrebiti PCA proces na podatke sa određenom količinom redundantnosti na taj način što će svi redundantni podaci biti uklonjeni iz inicijalne baze podataka. Vrednost informacija koje sadrži matrica (vektor) nakon redukcije biće zadržana, ali će sada biti u optimizovanom obliku sa manjim brojem promenljivih (Slika 4.1). Zadatak PCA analize u ovom istraživanju je ukloniti redundantne podatke unutar svake kategorije dva analizirana ekonomski sistema ponaosob. Drugi zadatak PCA metode je ekstrakcija najvažnijih informacija iz prvobitne baze podataka i priprema za njihovo dalje procesiranje. Ulazni vektori neuronske mreže biće formirani nakon izvršene redukcije i uspostavljanja relacija između ažuriranih parametara unutar 6 kategorija.

Upotrebom PCA metode formiraju se nove promenljive koje se nazivaju glavne komponente i koje se dobijaju kao linearna kombinacija originalnih inicijalnih promenljivih (Abdi, 2010). Metoda uključuje projekciju skupova podataka na novi koordinatni sistem određivanjem jediničnih vektora i jediničnih matrica. Osnovne operacije pri PCA procesiranju podataka su nalaženje srednje vrednosti skupa podataka, utvrđivanje standardne devijacije, varijanse i kovarijanse. PCA direktno određuje jedinične vektore i jedinične vrednosti iz matrice kovarijanse. Ova matrica određuje koliko variraju vrednosti parametara u odnosu na srednju vrednost skupa podataka, a u zavisnosti od drugih parametara. Utvrđivanje najosetljivijih parametara (parametara sa najvećim varijacijama) i njihova identifikacija su

početni koraci formiranja optimizovanih vektora podataka koji će se koristiti za obuku neuronske mreže.

Tabela 4.1 Inicijalni parametri po kategorijama: 1 - Glavni ekonomski indikatori, 2 - Realni indikatori, 3 - Tržišni indikatori, 4 - Finansijski indikatori, 5 - Državni indikatori, 6 - Eksterni indikatori

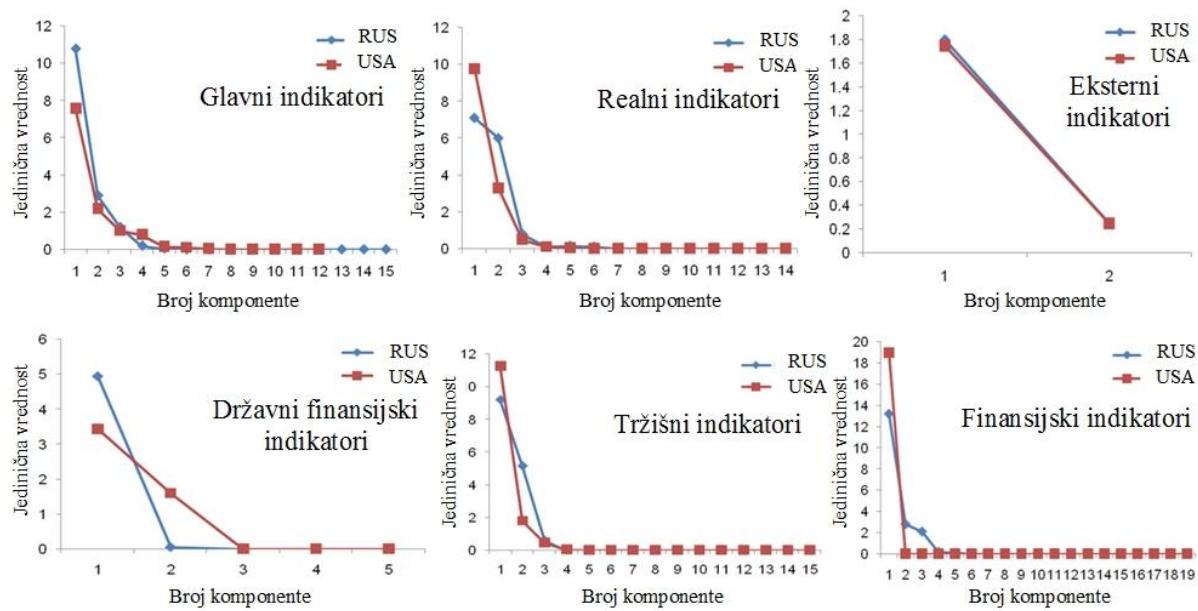
1	Nacionalna valuta po SDR	2	BDP (u milionima) - nominalni
	Realni efektivni kurs		BDP (u milionima) – deflator
	Kamatna stopa – godišnja (%)		Troškovi potrošnje domaćinstava
	Kamatna stopa – tržišna vrednost (%)		Troškovi potrošnje javnog sektora
	Kamatna stopa – vrednost u valuti		Bruto iznos kapitalnih investicija
	Rezerve - ukupno		Promene zaliha
	Rezerve – ukupno minus zlato		Izvoz dobara i usluga
	Težina rezervi plemenitih metala		Uvoz dobara i usluga
	Pozicija rezervi fonda države		BDP vrednost
	Rezerve – posedovanje SDR		Troškovi potrošnje domaćinstava - prilagođeno
3	Rezerve – inostrana razmena	4	Troškovi potrošnje javnog sektora - prilagođeno
	Cene i proizvodnja – potrošačke cene		Bruto iznos kapitalnih investicija - prilagođeno
	Cene i proizvodnja – Industrijska proizvodnja		Izvoz dobara i usluga - prilagođeno
	Cene i proizvodnja – Vrednost izvoza		Uvoz dobara i usluga - prilagođeno
	Cene i proizvodnja – Vrednost uvoza		
	Kamata		Ukupna imovina centralne banke
	Kratkoročna kamatna stopa		Depozitne korporacije
	Stopa popusta		Generalni javni sektor
	Vrednost obveznica javnog sektora		Stanovništvo
	Stopa pozajmica		Druge finansijske korporacije
5	Stopa tržišnog novca	6	Inostrano stanovništvo
	Sve akcije		Pasiva centralne banke - ukupno
	Cena akcija		Pasiva centralne banke – u novcu
	Indeks potrošačkih cena		Pasiva centralne banke – valuta u opticaju
	Ukupna maloprodajna trgovina		Pasiva centralne banke – u korporacijama
	Cene proizvodnje		Pasiva centralne banke – akcije i drugi kapital
	Industrijska proizvodnja		Neklasifikovana imovina i pasiva (NIP)
	Stopa nezaposlenosti		NIP - ukupno
	Nacionalna valuta po jednom dolaru		NIP – centralna banka
	Nacionalna valuta po jednom dolaru (prosek)		NIP – javni sektor
	Prihod		NIP – ostalo stanovništvo
	Takse		NIP – finansijske korporacije
	Troškovi		NIP – drugo
	Ukupni troškovi - gotovina		NIP – inostrano stanovništvo
	Kompenzacija zaposlenih		



Slika 4.1 Grafički prikaz preprocesiranja informacija i dovođenje optimizovanih podataka na ulaze neuronske mreže

### 4.3 Rezultati primene PCA metode

Primenom PCA metode na šest kategorija parametara iz prethodnog potpoglavlja (Tabela 4.1) dobijeni su dominantni ekonomski parametri dva sistema. Analiza je urađena korišćenjem softverskog paketa IBM SPSS Statistics. Na slici 4.2 su prikazana poređenja dva ekonomskih sistema za svaku kategoriju posebno. Sa slike se lako mogu uočiti dominantne komponente (parametri) sa najvećim jediničnim vrednostima: X osa predstavlja listu komponenti, dok Y osa predstavlja jedinične vrednosti za svaku od ovih komponenti. Jedinične vrednosti govore o stepenu dominantnosti svakog parametra ponaosob. Sa slike se dominantni parametri mogu i vizuelno izdvojiti bez potrebe za daljim analizama (parametri sa najvećim jediničnim vrednostima). Ipak, za pojedine ekonomске kategorije poželjno je uraditi dodatne analize kako bi se utvrdio značaj svih dominantnijih komponenti. Na taj način se na osnovu njihove precizno određene vrednosti može doneti odluka koji parametri će se na dalje koristiti, a koji će biti zanemareni i izostavljeni. Kategorije koje će biti podvrge dodataknim analizama za oba ekonomskih sistema su Glavni ekonomski indikatori, Realni indikatori i Tržišni indikatori. Detaljnija analiza biće urađena i za kategoriju finansijskih indikatora za ruski sistem, kao i kategorija Državnih indikatora za američki ekonomski sistem.



Slika 4.2 Grafički prikaz dominantnih ekonomskih parametara u okviru 6 kategorija

Zadatak naredne analize je evaluacija važnosti svake izabrane dominantne komponente sa slike 4.2. Ovo će odrediti mogućnost dalje redukcije ekstraktovanih komponenti. Analiza je izvršena korišćenjem matrice komponenti (Tabele 4.2.1-4.2.4 i 4.3.1-4.3.4), gde je pojedinačno pronađena zavisnost između svake dominantne komponente i ostalih komponenti iz kategorije kojoj ona pripada. U tabelama 4.2.1-4.2.4 i 4.3.1-4.3.4 prikazane su zavisnosti samo za najjače korelacije. Dobrim dominantnim parametrom se smatra onaj čije su korelacijske vrednosti sa drugim parametrima što bliže vrednosti 1, za svako poređenje. Što je korelacija između dva elementa bliža jedinici, njihova međusobna veza je sve jača. Dalje, što je međusobna veza jača, dominantni parametar će bolje predstavljati parametre koji nisu dominantni. Konačno, dominantni parametri koji poseduju najmanje koeficijente korelacija sa nedominantnim parametrima (Tabele 4.2.1-4.2.4 i 4.3.1-4.3.4) biće isključeni iz daljih analiza i neće biti uzeti kao predstavnici svojih kategorija. Nakon završetka procedura redukcije dimenzija, od 140 inicijalnih parametara (za oba ekonomskog sistema), formirano je 12 dominantnih komponenti ruskog ekonomskog sistema i 9 komponenti američkog. Novoformirane komponente prikazane su u tabeli 4.4.

U sledećem potpoglavlju će biti predstavljena procedura uspostavljanja relacija i zavisnosti između najdominantnijih komponenti. Nakon uspostavljanja međusobnih relacija biće formirani ulazni i izlazni vektori buduće neuronske mreže i na taj način završena faza pripreme i optimizacije početne baze trening podataka.

Tabela 4.2.1 Korelacije između dominantnih i nedominantnih komponenti – Rusija

Matrica komponenti – Glavni ekonomski parametri	Komponenta			
	1	2	3	4
Težina rezervi plemenitih metala	0,99	-0,06	0,02	0,05
Rezerve - ukupno	0,99	-0,01	-0,01	-0,08
Rezerve – ukupno minus zlato	0,99	-0,01	-0,01	-0,08
Rezerve – inostrana razmena	0,99	-0,02	-0,02	-0,09
Cene i proizvodnja – potrošačke cene	0,98	0,13	0,04	0,08
Rezerve – posedovanje SDR	0,98	0,13	0,04	0,08
Realni efektivni kurs	0,97	0,11	0,09	0,15
Cene i proizvodnja – industrijska proizvodnja	0,97	-0,15	-0,07	0,07
Pozicija rezervi državnog fonda	0,97	-0,03	0,06	0,03
Kamatna stopa (%) - godišnja	0,92	0,20	0,18	0,21
Kamatna stopa (%) – tržišna vrednost	-0,93	0,36	-0,01	-0,09
Kamatna stopa – vrednost u valutu	-0,28	0,92	0,26	0,04
Cena i proizvodnja – vrednost izvoza	-0,47	0,78	0,29	0,27
Cena i proizvodnja – vrednost uvoza	-0,54	-0,75	0,32	0,18
Nacionalna valuta po SDR	0,26	-0,07	0,91	-0,29

Tabela 4.2.2 Korelacije između dominantnih i nedominantnih komponenti – Rusija

Matrica komponenti – Realni indikatori	Komponenta	
	1	2
BDP – nominalna cena	0,85	0,40
BDP – deflator	0,83	0,53
Troškovi potrošnje domaćinstava	0,83	0,53
Uvoz dobara i usluga	0,82	0,5
Izvoz dobara i usluga	0,77	0,58
Troškovi potrošnje javnog sektora	0,68	0,62
Bruto iznos kapitalnih investicija	-0,57	0,79
Uvoz dobara i usluga – prilagođeno	-0,62	0,769
BDP vrednost	-0,63	0,77
Troškovi potrošnje javnog sektora - prilagođeno	-0,62	0,76
Troškovi potrošnje domaćinstava - prilagođeno	-0,64	0,75
Bruto iznos kapitalnih investicija - prilagođeno	0,64	0,76
Izvoz dobara i usluga – prilagođeno	-0,68	0,72
Promene zaliha	-0,16	0,52

Tabela 4.2.3 Korelacije između dominantnih i nedominantnih komponenti – Rusija

Matrica komponenti – Finansijski indikatori	Komponenta		
	1	2	3
NIP – drugo	0,99	0,04	0,08
NIP – ostalo stanovništvo	0,98	0,04	0,08
NIP – ukupno	0,98	0,12	0,06
NIP – inostrano stanovništvo	0,98	-0,13	0,03
NIP – finansijske korporacije	0,98	0,06	0,09
Pasiva centralne banke - ukupno	0,95	-0,06	0,29
Ukupna imovina centralne banke	0,95	-0,06	0,29
NIP – javni sektor	0,95	0,11	-0,23
Pasiva centralne banke – akcije i drugi kapital	0,94	-0,19	-0,25
Inostrano stanovništvo	0,93	-0,05	0,14
Druge finansijske korporacije	0,92	-0,21	-0,18
Ostalo stanovništvo	0,92	-0,22	-0,18
Pasiva centralne banke – valuta u opticaju	0,91	0,38	-0,06
Druge depozitne korporacije	0,78	-0,05	0,48
NIP – centralna banka	-0,04	0,98	0,10
Pasiva centralne banke – u korporacijama	-0,31	0,94	0,06
Pasiva centralne banke – u novcu	0,64	0,75	-0,03
Državni javni sektor	-0,34	0,07	0,90
Neklasifikovana imovina i pasiva	-0,28	-0,28	0,78

Tabela 4.2.4 Korelacije između dominantnih i nedominantnih komponenti – Rusija

Matrica komponenti – Tržišni indikatori	Komponenta		
	1	2	3
Stopa pozajmica	-0,99	0,06	0,04
Ukupna maloprodajna trgovina	0,98	-0,03	0,18
Sve akcije	0,97	-0,23	-0,08
Cena proizvodnje	0,96	0,11	0,25
Cena akcija	0,94	-0,33	-0,06
Industrijska proizvodnja	0,89	-0,44	-0,04
Stopa tržišnog novca	-0,86	0,06	0,51
Vrednost obveznica	-0,76	0,56	0,32
Nacionalna valuta po jednom dolaru	0,76	0,57	0,32
Kamata	0,75	0,65	0,14
Indeks potrošačkih cena	0,71	0,70	0,06
Nacionalna valuta po dolaru - prosek	-0,14	0,98	-0,11
Kratkoročna kamatna stopa	-0,32	-0,93	0,18
Stopa popusta	-0,32	-0,93	0,18
Stopa nezaposlenosti	-0,61	0,77	-0,17

Tabela 4.3.1 Korelacije između dominantnih i nedominantnih komponenti – Amerika

Matrica komponenti – Glavni ekonomski indikatori	Komponenta				
	1	2	3	4	5
Nacionalna valuta po SDR	-0,65	-0,28	-0,60	-0,21	0,31
Realni efektivni kurs	-0,73	-0,61	0,07	-0,09	-0,16
Kamatna stopa (%) – tržišna vrednost	-0,27	-0,61	0,57	0,43	0,19
Rezerve - ukupno	0,99	0,05	-0,01	0,02	0,02
Rezerve – ukupno minus zlato	0,99	0,05	-0,01	0,02	0,02
Težina rezervi plemenitih metala	0,99	0,01	-0,08	0,06	0,01
Rezerve – posedovanje SDR	-0,97	-0,13	0,17	0,02	0,04
Rezerve – inostrana razmena	-0,03	0,58	0,62	-0,51	0,13
Cene i proizvodnja – potrošačke cene	0,98	-0,06	0,02	0,08	0,09
Cene i proizvodnja – industrijska proizvodnja	0,98	-0,07	0	0,08	0,06
Cena i proizvodnja – Vrednost izvoza	-0,57	0,75	-0,08	0,31	0,03
Cena i proizvodnja – vrednost uvoza	-0,58	0,75	-0,07	0,30	0,03

Tabela 4.3.2 Korelacije između dominantnih i nedominantnih komponenti – Amerika

Matrica komponenti – Državni ekonomski indikatori	Komponen.	
	1	2
Prihodi	0,92	0,41
Takse	0,94	0,35
Ukupni troškovi, u novcu	-0,62	0,78
Troškovi, ostalo	-0,62	0,78
Kompenzacije zaposlenih	0,96	0,29

Tabela 4.3.3 Korelacije između dominantnih i nedominantnih komponenti – Amerika

Matrica komponenti – Realni indikatori	Komponenta		
	1	2	3
BDP – nominalna cena	0,99	0,05	0,11
BDP – deflator	0,98	-0,14	0,11
Troškovi potrošnje domaćinstava	0,99	0,01	0,09
Troškovi potrošnje javnog sektora - prilagođeno	0,93	-0,35	0,04
Bruto iznos kapitalnih investicija	-0,33	0,86	0,35
Promene zaliha	0,34	0,64	-0,68
Izvoz dobara i usluga	0,99	0,04	0,02
Uvoz dobara i usluga	0,92	0,32	-0,02
BDP vrednost	0,90	0,39	0,16
Troškovi potrošnje javnog sektora	0,96	0,23	0,11
Bruto iznos kapitalnih investicija - prilagođeno	0,62	-0,75	-0,07
Izvoz dobara i usluga – prilagođeno	0,99	0,03	0,03
Uvoz dobara i usluga – prilagođeno	0,67	0,71	-0,14

Tabela 4.3.4 Korelacije između dominantnih i nedominantnih komponenti – Amerika

Matrica komponenti – Tržišni indikatori	Komponenta		
	1	2	3
Kamata	0,24	0,95	-0,05
Kratkoročna kamatna stopa	0,99	-0,03	-0,02
Stopa popusta	0,99	-0,03	-0,02
Vrednost obveznica	0,77	0,56	-0,25
Stopa pozajmica	0,99	-0,03	-0,02
Stopa tržišnog novca	0,73	0,44	0,52
Sve akcije	0,97	-0,24	0,01
Cena akcija	0,94	-0,33	0,04
Indeks potrošačkih cena	0,99	-0,09	-0,01
Ukupna maloprodajna trgovina	0,99	-0,14	0,002
Cena proizvodnje	0,98	-0,17	-0,01
Industrijska proizvodnja	0,99	-0,11	0,007
Stopa nezaposlenosti	0,98	0,16	-0,15

Tabela 4.4 Dominantne komponente dva ekonomskaa sistema

	Kategorija	Rusija	Amerika	
1	<b>Glavni ekonomski indikatori</b>	Tržišni kurs	Tržišni kurs	1
2		Realni efektivni kurs	Realni efektivni kurs	2
3		Kamatna stopa popusta		
4	<b>Realni ekonomski indikatori</b>	Nominalni BDP	Nominalni BDP	3
5		BDP deflator	BDP - Deflator	4
6	<b>Eksterni indikatori</b>	Ukupna aktiva rezervi	Ukupna aktiva rezervi	5
7	<b>Finansijski indikatori</b>	Ukupna aktiva centralne banke	Ukupna aktiva centralne banke	6
8		Druge finansijske korporacije		
9		Generalni javni sektor		
10	<b>Državni finansijski indikatori</b>	Prihodi	Prihodi	7
11			Takse	8
12	<b>Tržišni indikatori</b>	Kamata Kratkoročna kamatna stopa	Kamata	9

#### 4.4 Međusobne zavisnosti i procedura formiranja ulaznih vektorâ

Nakon završetka odabira dominantnih komponenti potrebno je pristupiti formirajuju ulazno/izlaznih vektorâ neuronske mreže. Uticaj dominantnih parametara na mrežu biće određen na osnovu važnosti samih parametara. Uticaj parametara biće predstavljen koeficijentima  $\alpha_1, \alpha_2, \dots, \alpha_6$  za svaku kategoriju respektivno. Cilj je formirati koeficijent kojim će biti pokazana važnost dominantnog parametra na celokupnu optimizovanu bazu podataka. Na primer, ako su izabrana tri dominantna parametra iz kategorije koja ima 19 parametara, ti parametri će imati veći koeficijent važnosti u poređenju sa 3 odabrana dominantna parametra koji su izabrani iz kategorije sa 5 parametara. Koeficijenti će biti izračunati korišćenjem jednačine:

$$\alpha_i = \frac{K_i}{70}, \quad (4.1)$$

gde je promenljiva  $K_i$  broj parametara  $i$ -te kategorije, dok je 70 ukupni broj parametara jednog ekonomskog sistema. Numeričke vrednosti koeficijenata se nakon primene jednačine 4.1

dobijaju u sledećem obliku:  $\alpha_1 = 0.241$ ,  $\alpha_2 = 0.2$ ,  $\alpha_3 = 0.029$ ,  $\alpha_4 = 0.271$ ,  $\alpha_5 = 0.071$ ,  $\alpha_6 = 0.214$ .

Poslednji korak procedure formiranja ulaznih vektora je normiranje dominantnih parametara. Da bi se postigao željeni kvalitet finalnih oblika ulaznih vektora, biće primenjena metoda standardne devijacije u okviru svake kategorije zasebno. Time će ceo opseg vrednosti dominantnih parametara biti normiran i prilagođen za njihovu efikasniju obradu pomoću neuronske mreže. Standardna devijacija biće određena na osnovu jednačine:

$$s^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1} = \frac{\sum_{i=1}^n \left( X_i - \left( \sum_{i=1}^n X_i \right) / n \right)^2}{n-1}, \quad (4.2)$$

gde je  $X_i$   $i$ -ti dominantni parameter, a  $n$  broj dominantnih parametara u okviru svake kategorije. Konačne vrednosti ulaznog vektora se dobijaju multiplikacijom sa odgovarajućim koeficijentima (nakon pronalaženja vrednosti standardne devijacije):

$$X_{CAT} = \alpha_i s_{CAT}, \quad (4.3)$$

gde je  $X_{CAT}$  konačni ulazni vektor,  $\alpha_i$  odgovarajući koeficijent (gde  $i$  uzima vrednosti od 1 do 6) i  $s_{CAT}$  odgovarajuća vrednost standardne devijacije. Jednačine svih ulaznih vektora predstavljene su u tabeli 4.5. U sledećem potpoglavlju će novoformirana baza podataka biti testirana na projektovanoj neuronskoj mreži.

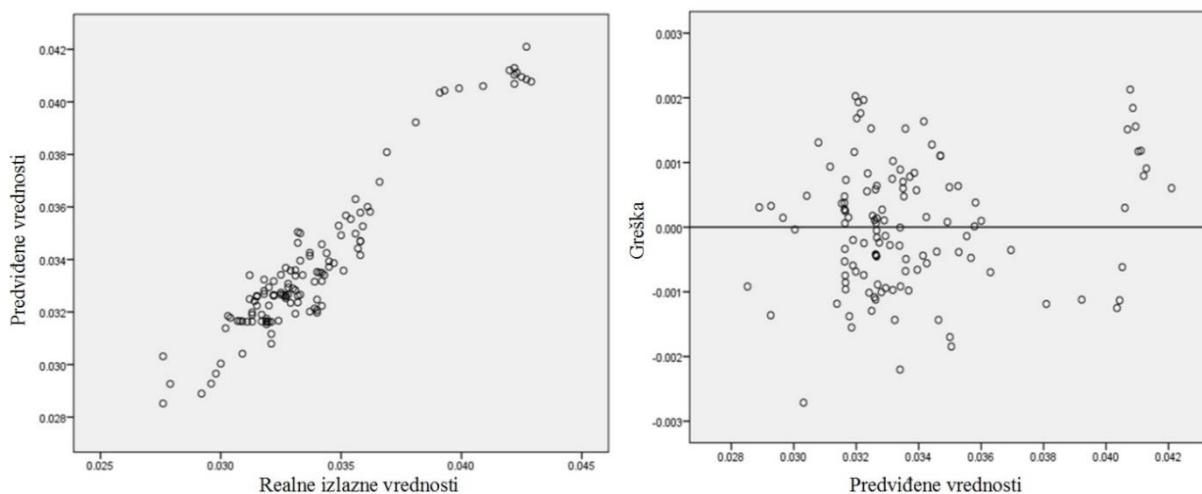
Tabela 4.5 Procedura formiranja ulaznih vektora

Zemlja	Kategorija	Ulazni vektor	Jednačina
RUS	Glavni ekonomski indikatori	$X_{mei}$	$X_{mei} = \alpha_1 s_{Rmei}$
RUS	Realni ekonomski indikatori	$X_{rsi}$	$X_{rsi} = \alpha_2 s_{Rrsi}$
RUS	Eksterni indikatori	$X_{esi}$	$X_{esi} = \alpha_3 s_{Resi}$
RUS	Finansijski indikatori	$X_{fsi}$	$X_{fsi} = \alpha_4 s_{Rfsi}$
RUS	Državni finansijski indikatori	$X_{gsi}$	$X_{gsi} = \alpha_5 s_{Rgsi}$
RUS	Tržišni indikatori	$X_{msi}$	$X_{msi} = \alpha_6 s_{Rmsi}$
USA	Glavni ekonomski indikatori	$y_{mei}$	$Y_{mei} = \alpha_1 s_{Umei}$
USA	Realni ekonomski indikatori	$y_{rsi}$	$Y_{rsi} = \alpha_2 s_{Ursi}$
USA	Eksterni indikatori	$y_{esi}$	$Y_{esi} = \alpha_3 s_{Uesi}$
USA	Finansijski indikatori	$y_{fsi}$	$Y_{fsi} = \alpha_4 s_{Ufsi}$
USA	Državni finansijski indikatori	$y_{gsi}$	$Y_{gsi} = \alpha_5 s_{Ugsi}$
USA	Tržišni indikatori	$y_{msi}$	$Y_{msi} = \alpha_6 s_{Umsi}$

## 4.5 Projektovanje neuronske mreže i simulacioni rezultati

Za potrebe simulacije formirana je elementarna troslojna *feedforward* neuronska mreža sa 12 ulaza i jednim izlazom. Odabrana je aktivaciona funkcija tipa standardne hiperbolične sigmoidne funkcije (tansig) i integrisana u okviru mreže. Broj neurona unutar skrivenog sloja mreže je tri. Ulagani trening vektori su formirani na osnovu parametara i procedure opisane u prethodnom potpoglavlju. Odgovarajući izlazni trening vektor neuronske mreže formiran je korišćenjem realnih kursnih vrednosti RUB/DOL za period 2008-2012. Mreža je prošla kroz proceduru serijskog treninga i optimizacija tokom ciklusa učenja izvršena je na osnovu praćenja vrednosti opadajućeg gradijenta. Grafički prikaz relacija između predviđenih i realnih izlaznih vrednosti mogu se videti na slici 4.3 levo. Na slici 4.3 desno mogu se uočiti greške predviđenih vrednosti koje je napravila neuronska mreža u poređenju sa stvarnim vrednostima.

Greška predikcije kursa novčane valute se javlja u opsegu od 0 do  $\pm 0.003$ , što u procentima predstavlja grešku od 0 do 1% koju neuronska mreža pravi tokom predikcije. Treba naglasiti da se najveći deo predviđenih vrednosti javlja sa greškom u opsegu od 0 do 0,5%, što je dobra polazna osnova za dalja istraživanja. Ukupne vrednosti srednjekvadratnih i relativnih grešaka dobijenih radom mreže sa test uzorcima prikazane su u tabeli 4.6. Iz sumiranih rezultata se može zaključiti da su greške pri testiranju manje od grešaka dobijenih tokom treninga. To se može uzeti kao dobar rezultat koji pokazuje da je procedura učenja bila efektivna i da su ulazno/izlazni trening vektori formirani na zadovoljavajući način.



Slika 4.3 Grafički prikaz rezultata testiranja primenjene optimizacione procedure (relacije predviđenih i stvarnih vrednosti na slici levo, i greške predviđenih vrednosti na slici desno)

Tabela 4.6 Sumirani rezultati rada neuronske mreže

Faza treninga	Srednjekvadratna greška	3.879
	Relativna greška	0.090
Faza testiranja	Srednjekvadratna greška	3.008
	Relativna greška	0.086

Predstavljena optimizaciona metoda u ovom poglavlju se pokazala kao dobra polazna osnova za dalji razvoj metodologije preprocesiranja trening podataka neuronske mreže. Bolje rezultate je moguće postići modifikacijama strukture same mreže: promenom tipa mreže, broja skrivenih slojeva i broja neurona, promenom trenažnog procesa, stope učenja, uvođenjem kašnjenja (*time delay*) ulaznih parametara. Rezultati optimizacione metode su primenjeni na elementarnu troslojnju mrežu sa samo tri neurona u skrivenom sloju i dokazano je da i takva jednostavna mreža može biti dovoljna za dobijanje zadovoljavajućih rezultata ukoliko se podaci preprocesiraju na optimalan način.

# **5 Upotreba ortogonalnih funkcija u neuronskim mrežama**

## **5.1 Ortogonalne funkcije**

Problem rešavanja diferencijalnih jednačina na beskonačnim ili polu-beskonačnim intervalima kao i dobijanje razvoja proizvoljnih funkcija u takvim intervalima, privukao je pažnju mnogih matematičara u 19. veku. Rešavanje tog problema dovelo je do razvoja ortogonalnih funkcija koje su našle široku primenu u nauci i inženjerskim oblastima poput telekomunikacija, obradi digitalnih signala, digitalnim filtrima, obradi slike, računarskom projektovanju elektronskih kola, itd. Istraživači su paralelno sa razvojem različitih klasa ovih polinoma (koje se izvode iz generalizovanih ortogonalnih polinoma) proučavali i različite tipove upravljačkih problema za čije bi se rešavanje oni mogli koristiti. To je dovelo do njihove popularnosti i u oblasti automatike, gde su svoju primenu našle u realizaciji i unapređenju upravljačkih logika sistema automatskog upravljanja.

Pojam ortogonalnosti se može objasniti preko proizvoda dva vektora. Dva normirana vektora smatraju se ortogonalnim ukoliko im je skalarni proizvod jednak nuli. Ukoliko su im pravci približno jednaki, njihov skalarni proizvod biće jednak jedinici. Ortogonalnost razvoja omogućava modeliranje sistema i aproksimaciju sa razvojem konačne dužine. Važna karakteristika ortogonalnih funkcija je da prilikom aproksimacija ispoljavaju minimalne vrednosti srednje kvadratnih grešaka. Njihovom upotrebom moguće je uspešno predstaviti različite tipove funkcija na osnovu čega se za njih može reći i da su univerzalni aproksimatori funkcija. U narednim potpoglavlјima biće predstavljeni tipovi ortogonalnih funkcija koje će biti korišćene u nastavku doktorske disertacije.

### **5.1.1 Generalizacija kvazi-ortogonalnih polinoma Ležandrovog tipa**

Koncept „kvazi ortogonalnost“ prvi put je uveden još 1923. godine u radu Riesa (Riesz, 1923) kao deo matematičkog aparata za rešavanje problema momenta u mehanici. Kvazi ortogonalne funkcije, a posebno kvazi ortogonalni polinomi, razmatrani su u radovima (Chihara, 1957; Alfaro, 1991; Brezinski, 2004). Kvazi ortogonalni polinomi pogodni za modeliranje dinamičkih sistema prikazani su u radovima (Milojković, 2013; Milojković, 2015; Perić, 2016; Nikolić, 2016b). U slučaju rada sa nesavršenim sistemima (kod kojih se prilikom

modeliranja zanemaruje određena dinamika sistema) se tokom definisanja potrebnog matematičkog aparata uvode konstante  $\varepsilon$  i  $\delta$  (Danković, 2009a; Milojković; 2010; Antić, 2012b). Razlog za to je želja za što boljom reprezentacijom modela, a same konstante predstavljaju kvantitativne vrednosti nepouzdanosti koje opisuju nesavršenost sistema. Njihova varijacija sadrži kumulativne uticaje svih nesavršenih elemenata, izmerene šumove na izlazima sistema i nepouzdanosti samog modela.

Prednost upotrebljenih ortogonalnih funkcija u nabrojanim radovima je ta da su razvijene korišćenjem transformacija u kompleksnom domenu - što ih čini prikladnim pri analizi i sintezi kontinualnih sistema. U ovom poglavlju će biti napravljen korak dalje i biće demonstriran proces generisanja generalizovanih ortogonalnih polinoma specijalno projektovanih za primenu u okviru endokrinog ANFIS-a. Ovakvi polinomi sadrže adaptivnu meru promenljivosti sistema (za rad u realnom okruženju) koja je prikladna za modeliranje korišćenjem hormonalnog efekta. U nastavku će, za potrebe istraživanja ove doktorske disertacije, biti date neophodne jednačine koje će se koristiti za realizaciju novih tipova neuronskih mreža. Kompletan matematički aparat kojim su opisane ortogonalne i kvazi ortogonalne funkcije može se naći u radovima koji su navedeni na početku ovog potpoglavlja.

Klasični ortogonalni polinomi mogu se predstaviti u obliku  $P_n(x) = \sum_{k=0}^n a_k x^k$  (Szegö,

1975). Unutrašnji proizvod dva polinoma ovog skupa može se definisati kao:

$$(P_m(x), P_n(x)) = \int_a^b w(x) P_m(x) P_n(x) dx, \quad (5.1.1)$$

gde je  $w(x)$  težinska funkcija, a  $a$  i  $b$  su granice ortogonalnog intervala. Ortogonalnost polinoma može se definisati i na sledeći način:

$$(P_m(x), P_n(x)) = \begin{cases} 0, & m \neq n, \\ N_n \neq 0, & m = n. \end{cases} \quad (5.1.2)$$

Na drugoj strani, ukoliko je tačno da važi:

$$(P_m(x), P_n(x)) = \begin{cases} \varepsilon \approx 0, & m \neq n, \\ N_n \neq 0, & m = n. \end{cases} \quad (5.1.3)$$

gde je  $\varepsilon$  konstanta bliska ali ne i jednaka nuli ( $\varepsilon \approx 0$ ), onda se može govoriti o skoro ortogonalnim polinomima (Milojković, 2010). Veza između klasičnih i skoro ortogonalnih polinoma (Danković, 2009a) data je sledećom relacijom:

$$P_n^{(\varepsilon)}(x) = P_n(x) + \sum_{k=1}^{n-1} \frac{b_k(\varepsilon)}{\|P_k\|^2} P_k(x), \quad (5.1.4)$$

gde je  $\|P_k\|^2$  kvadrat norme, a  $b_k(\varepsilon)$  su polinomi zavisni od  $\varepsilon$  i mogu se predstaviti kao:

$$b_{k+1}(\varepsilon) = b_k(\varepsilon) - \frac{b_k^2(\varepsilon)}{\|P_k\|^2}, \quad b_0 = \varepsilon. \quad (5.1.5)$$

Za dalji razvoj potrebnih funkcija važi da je  $\delta = 1 + \varepsilon \approx 1$ . Ukoliko se definicija skoro ortogonalnosti primeni na šiftovane Ležandrove polinome u eksplisitnoj formi:

$$P_n(x) = \frac{1}{n!} \sum_{j=0}^n (-1)^{n-j} \binom{n}{j} \frac{(n+j)!}{j!} x^j, \quad (5.1.6)$$

dobiće se sekvenca poboljšanih skoro ortogonalnih Ležandrovih polinoma (Antić, 2012b; Nikolić 2016b):

$$P_n^{(\delta)}(x) = \sum_{i=0}^n A_{n,i}^{\delta} x^i, \quad (5.1.7)$$

gde je:

$$A_{n,i}^{\delta} = (-1)^{n+i} \frac{\Gamma(n\delta+i+1)}{\Gamma(n\delta+1)i!(n-i)!}, \quad (5.1.8)$$

i  $\Gamma$  je simbol gama funkcije. Konačno, generalizacija ortogonalnosti može se predstaviti definicijom kvazi-ortogonalnosti na skupu polinoma  $P_n(x)$  (Brezinski, 2004):

$$(P_n^k(x), P_m^k(x)) = \int_a^b w(x) P_n^k(x) P_m^k(x) dx = \begin{cases} 0, & 0 \leq m \leq n-k-1, \\ N_{n,m}^k \neq 0, & n-k \leq m \leq n, \end{cases} \quad (5.1.9)$$

gde  $k$  predstavlja red kvazi-ortogonalnosti,  $a$  i  $b$  su granice kvazi ortogonalnog intervala, a  $w(x)$  je težinska funkcija.

Ukoliko se poboljšani skoro ortogonalni Ležandrovi polinomi (5.1.7) i (5.1.8) primene na (5.1.9), dobiće se generalizovani kvazi-ortogonalni Ležandrovi polinomi na intervalu  $(0,1)$  sa težinskom funkcijom  $w(x) = 1$ :

$$P_n^{(k,\delta)}(x) = \sum_{i=0}^n A_{n,i}^{k,\delta} x^i, \quad (5.1.10)$$

gde je:

$$A_{n,i}^{(k,\delta)} = (-1)^{n+i+k} \frac{\prod_{j=1}^{n-k} (i + j\delta)}{i!(n-i)!}. \quad (5.1.11)$$

U jednačini (5.1.10)  $k$  predstavlja red kvazi-ortogonalnosti, a  $\delta$  je konstanta veoma bliska jedinici (Antić, 2012b). Prvih nekoliko generalizovanih kvazi-ortogonalnih polinoma prvog reda ( $k=1$ ) ove sekvene su:

$$\begin{aligned} P_1^{(1,\delta)}(x) &= -x + 1, \\ P_2^{(1,\delta)}(x) &= -\frac{(\delta+2)}{2}x^2 + (\delta+1)x - \frac{\delta}{2}, \\ P_3^{(1,\delta)}(x) &= -\frac{(\delta+3)(2\delta+3)}{6}x^3 + (\delta+1)(\delta+2)x^2 - \frac{(\delta+1)(2\delta+1)}{2}x + \frac{\delta^2}{3}, \\ P_4^{(1,\delta)}(x) &= -\frac{(\delta+2)(\delta+4)(3\delta+4)}{12}x^4 + \frac{(\delta+1)(\delta+3)(2\delta+3)}{2}x^3 - \\ &\quad - \frac{(\delta+1)(\delta+2)(3\delta+2)}{2}x^2 + \frac{(\delta+1)(2\delta+1)(3\delta+4)}{6}x - \frac{\delta^3}{4}, \\ &\dots \end{aligned} \quad (5.1.12)$$

Ukoliko se primeni inverzna Laplasova transformacija, prethodna sekvenca može se predstaviti u obliku:

$$\begin{aligned} \varphi_1^{(1,\delta)}(t) &= -e^{-t} + 1, \\ \varphi_2^{(1,\delta)}(t) &= -\frac{(\delta+2)}{2}e^{-2t} + (\delta+1)e^{-t} - \frac{\delta}{2}, \\ \varphi_3^{(1,\delta)}(t) &= -\frac{(\delta+3)(2\delta+3)}{6}e^{-3t} + (\delta+1)(\delta+2)e^{-2t} - \frac{(\delta+1)(2\delta+1)}{2}e^{-t} + \frac{\delta^2}{3}. \end{aligned} \quad (5.1.13)$$

Nakon uvođenja smene  $x = e^{-t}$  u (5.1.13) i primene Laplasove transformacije, dobija se racionalna funkcija  $k$ -tog reda u formi funkcije prenosa, koja je prikladna za modeliranje kontinualnog dinamičkog sistema (Nikolić, 2016a):

$$W_n^{(k,\delta)}(s) = \frac{\prod_{i=1}^{n-k}(s-i\delta)}{\prod_{i=0}^n(s+i)} = \frac{(s-\delta)(s-2\delta)\cdots(s-(n-k)\delta)}{s(s+1)(s+2)\cdots(s+n)}. \quad (5.1.14)$$

Takođe, kvazi-ortogonalnost se može definisati i preko unutrašnjeg proizvoda kao:

$$N_{nm}^{(k,\delta)} = \oint_C W_n^{(k,\delta)}(s) \bar{W}_m^{(k,\delta)}(s) w(s) ds, \quad (5.1.15)$$

sa težinskom funkcijom  $w(s)=1$ , gde je  $m>n$ . Koristeći transformaciju preslikavanja

$f(s) = s + \bar{s} = 0$  primenjenu na (5.1.14) dobija se:

$$\bar{W}_m^{(k,\delta)}(s) = \frac{\prod_{i=1}^{m-k}(s+i\delta)}{\prod_{i=0}^m(s-i)} = \frac{(s+\delta)(s+2\delta)\cdots(s+(m-k)\delta)}{s(s-1)(s-2)\cdots(s-m)}. \quad (5.1.16)$$

Konačno, nakon primene Košijeve teoreme za rešavanje konturnog integrala (5.1.15) dobija se izraz:

$$N_{nm}^{(k,\delta)} = 2\pi j \sum_{r=1}^{m-k} \text{Res} \left[ W_n^{(k,\delta)}(s) \bar{W}_m^{(k,\delta)}(s) \right]. \quad (5.1.17)$$

### 5.1.2 Čebiševljevi polinomi prve vrste

Glavni razlozi primene ovih polinoma su osobina rekurzivnosti, kompletnost u graničnim tačkama koja garantuje precizne aproksimacije nelinearnih signala (Wang, 2009) i proračunska jednostavnost. Čebiševljevi polinomi biće definisani pomoću poznatih relacija na intervalu ortogonalnosti (-1, 1) (Abramovic, 1972):

$$\begin{aligned} T_n(x) &= \sum_{m=0}^n c_m x^m, \\ x^n &= b_n^{-1} \sum_{m=0}^n d_m T_m(x), \end{aligned} \quad (5.1.18)$$

gde  $T_n(x)$  predstavlja Čebiševljev polinom prve vrste  $n$ -tog reda, a  $b_n$ ,  $c_m$  i  $d_m$  su koeficijenti čije se vrednosti mogu odrediti iz jednačina opisanih u (Abramovic, 1972). Prvih nekoliko članova Čebiševljevih polinoma prve vrste su:

$$\begin{aligned} T_0(x) &= 1, \\ T_1(x) &= x, \\ T_2(x) &= 2x^2 - 1, \\ &\vdots \\ T_n(x) &= 2xT_{n-1}(x) - T_{n-2}(x). \end{aligned} \quad (5.1.19)$$

Naredna jednačina, koja predstavlja definiciju ortogonalnosti polinomnog skupa  $T_n(x)$  izražena preko unutrašnjeg proizvoda, definisana je za dva slučaja ( $m \neq n$  i  $m = n$ ) i može se naći u (Abramovic, 1972; Mastroianni, 2008):

$$\begin{aligned} \int_{-1}^1 \frac{T_m(x) T_n(x)}{\sqrt{1-x^2}} dx &= 0 \quad \text{za } m \neq n, \\ \int_{-1}^1 \frac{T_n(x) T_n(x)}{\sqrt{1-x^2}} dx &= \begin{cases} \pi, & \text{za } n=0 \\ \pi/2, & \text{za } n=1,2,3\dots \end{cases} \end{aligned} \quad (5.1.20)$$

Dalje u tekstu će označavanje polinomnog skupa  $T_n(x)$  biti promenjeno u  $\phi_{n+1}(x)$ . Razlog za to je već uspostavljena praksa predstavljanja funkcija u okviru ortogonalnih neuronskih mreža (Fang, 2000; Sher, 2001; Chen, 2004; Wang, 2009) koja će u disertaciji biti korišćena zbog

preglednosti (upotreba oznake  $\phi$  i indeksiranje elemenata od rednog broja 1). Sada se osnova funkcije može predstaviti kao:

$$\phi(x) = [\phi_1(x), \phi_2(x), \dots, \phi_{n+1}(x)]^T, \quad (5.1.21)$$

gde  $n$  predstavlja dimenziju Čebiševljeve funkcionalne ekspanzije. Dalje, proizvoljna funkcija  $y$  se može aproksimirati korišćenjem ortogonalnih funkcija kao:

$$y = F(X) = \sum_{i=1}^n w_i \phi_i(X) + R(X, n), \quad (5.1.22)$$

gde je  $\phi_i(X)$  ortogonalna funkcija,  $w_i$  je ograničen i jedinstven koeficijent i  $R(X, n)$  je ekspanziona greška koja se smanjuje sa povećanjem broja ekspanzionih elemenata ( $n$ ) (Sher, 2001). Ovi principi aproksimacije će biti upotrebljeni u sledećem potpoglavlju kao osnova za dalje razmatranje i nadogradnju.

Generalizacija skoro ortogonalnih i kvazi ortogonalnih funkcija i polinoma izvršena je u (Nikolić, 2016a; Nikolić, 2016b). Polinomi definisani na ovakav način predstavljaju kombinaciju dve klase polinoma koja je vrlo pogodna za dalja razmatranja. Implementacijom faktora nesavršenosti  $\delta$  može se dobiti bolja reprezentacija realnog modela dinamičkog sistema. Ovaj faktor može definisati meru promenljivosti datog sistema po pitanju uslova u kojima radi i prikladan je za modeliranje u vidu hormonalnog efekta koji se uvodi u ANFIS, što će biti i eksperimentalno dokazano u narednim poglavljima disertacije.

### 5.1.3 Kompleksne racionalne funkcije – ortogonalne trigonometrijske funkcije

Kompleksne racionalne funkcije intenzivno su se proučavale 70-ih i 80-ih godina prošloga veka, o čemu govore mnogi publikovani radovi na ovu temu (Gabor, 1946; Lang, 1981; Snelgrove, 1985). Racionalne funkcije s kompleksnim polovima (i odgovarajući kompleksni filtri) mogu, takođe, biti ortogonalne što je pokazano u radovima (Deun, 2003; Deckers, 2009). Ove funkcije su kasnije iskorišćene za projektovanje odgovarajućih kompleksnih filtera u smislu funkcije prenosa koju generiše njihova struktura (Sedra, 1985; Kiss, 2003). Sada će biti predstavljene kompleksne racionalne funkcije pomoću kojih se mogu generisati kompleksni Ležandrovi polinomi trigonometrijskog oblika. U kratkim crtama biće definisane nove kompleksne racionalne funkcije i polinomi, dok se kompletan matematički

aparat može naći u (Nikolić, 2014, Nikolić, 2016a). Kompleksna racionalna sekvenca  $W_n(t)$  se u vremenskom domenu može predstaviti na sledeći način (Nikolić, 2016a):

$$\begin{aligned} W_n(t) &= \sum_{i=1}^n A_i e^{s_i t} + \sum_{i=1}^n B_i e^{s_i^* t}, \\ W_n(t) &= \sum_{i=1}^n e^{\sigma_i t} (\alpha_i \cos \omega_i t + \beta_i \sin \omega_i t), \end{aligned} \quad (5.1.23)$$

gde su  $s_i$  kompleksni polovi i  $s_i^*$  njima odgovarajući konjugovano-kompleksni polovi, tj.  $s_i = \delta_i + j\omega_i$  i  $s_i^* = \delta_i - j\omega_i$ . Funkcije (5.1.23) predstavljaju inverznu Laplasovu transformaciju Hevisajdovog razvoja kompleksne racionalne funkcije  $W_n(s)$  i karakteriše ih ortogonalnost na intervalu  $(0, \infty)$  s težinom  $w(t) = 1$ , tj.

$$\int_0^\infty W_m(t) \cdot W_n(t) dt = \begin{cases} 0, & m \neq n \\ N_n^2, & m = n \end{cases} \quad (5.1.24)$$

Kompletan matematički dokaz ortogonalnosti dat je u (Nikolić, 2014; Nikolić, 2016a), a ovde će biti predstavljena samo prva tri člana sekvence kompleksnih polinoma u vremenskom domenu:

$$\begin{aligned} P_1(t) &= e^{-t} \sin t, \\ P_2(t) &= \frac{3}{10} e^{-2t} (4 \cos 2t + 3 \sin 2t) + \frac{2}{5} e^{-t} (-3 \cos t + \sin t), \\ P_3(t) &= \frac{2}{39} e^{-3t} (63 \cos 3t - 16 \sin 3t) + \\ &\quad + \frac{12}{65} e^{-2t} (-11 \cos 2t + 23 \sin 2t) - \frac{3}{5} e^{-t} (2 \cos t - \sin t), \\ &\dots \end{aligned} \quad (5.1.25)$$

U sledećem potpoglavlju biće dat prikaz implementacije ortogonalnih funkcija u okviru standardne neuronske mreže i upotreba realizovane ONN na poboljšanju upravljačkih performansi jednog laboratorijskog modela nelinearnog dinamičkog sistema.

## **5.2 Implementacija ortogonalnih aktivacionih funkcija unutar standardnih neuronskih mreža**

U ovom poglavlju fokus će biti na unapređenju performansi dvopozicione levitacije laboratorijskog modela magnetnog levitacionog sistema (MLS-a). Problem stabilne levitacije rešavan je od strane mnogih istraživača koji su pokušavali različitim metodama da poboljšaju levitacione performanse. Upravljačka šema dvopozicione levitacije bazirana na *lead-lag* upravljanju i upravljanju u kliznom režimu prikazana je u (Jeon, 2005). Još jedna upotreba kliznog režima za realizaciju upravljačke logike levitacionog sistema predstavljena je u (Chiang, 2011). Linearni i nelinearni regulatori za preciznu kontrolu pozicije metalne lopte tokom levitacije predstavljeni su u (Barie, 1996). Regulacija pozicije MLS-a je u (Peterson, 2006) ostvarena projektovanjem regulatora baziranim na upotrebi funkcije Ljapunova. Generalizovani proporcionalno-integralni (PI) regulator koji utiče na kompenzaciju greške tokom levitacije prikazan je u (Morales-Herrera, 2010). Regulator je obezbedio veću robustnost sistema i pokazao zadovoljavajuće eksperimentalne rezultate pri stabilizaciji levitacionog objekta i praćenju zadatih trajektorija levitacije. Sledeća široko primenjena tehnika za kontrolu pozicije levitacionog objekta je prediktivno upravljanje. U radovima (Bojan-Dragos, 2015; Sgaverdea, 2015) su prikazani simulacioni rezultati dobijeni korišćenjem ovog tipa upravljanja. U (Luat, 2014) prikazan je fazi-PID regulator koji koristi fazi logiku pri *online* podešavanju PID parametara. U dosadašnjim istraživanjima se pokazalo da konvencionalni regulatori podešeni pomoću neke inteligentne strukture vrlo često pružaju bolje performanse i veću fleksibilnost pri radu od standardno korišćenih regulatora. Primeri upotrebe fazi logike za potrebe kontrole levitacije prikazani su još u (Dragos, 2011; Ishaque, 2011; Precup, 2015; Farooq, 2015).

Drugi tip inteligentnih struktura koje nalaze primenu u ovoj oblasti su veštačke neuronske mreže. Za potrebe istraživanja u ovom poglavlju, biće iskorišćen laboratorijski model MLS-a, proizvođača Inteco (Internet dokument, 6). Glavni zadatak biće unapređenje performansi dvopozicione levitacije metalne lopte implementacijom neuronske mreže unutar upravljačke logike sistema. Implementacija neuronskih mreža unutar standardnih upravljačkih logika dinamičkih sistema donosi sa sobom efikasnije i poboljšano upravljanje (Tsirigotis, 2005). Korišćenje *feedforward* mreže sa jednim skrivenim slojem, u okviru upravljačke logike levitacionog sistema prikazano je u (Lairi, 1999). U (Saberri, 2012) je predstavljena neuronska mreža koja je korišćena za upravljanje elektromagnetskim sistemom za vešanje transportnih vozila. Edukativni rad (Shiakolas, 2004) opisuje okruženje digitalnog kontrolera koje se koristi

za potrebe upravljanja magnetnim levitacionim sistemom i koje je optimizovano implementacijom neuronske mreže. U radu (Haley, 1999) je referentni upravljački model levitacionog sistema predstavljen neuronskom mrežom, dok je ugrađeni linearni model iskorišćen za proceduru formiranja težinskih koeficijenata mreže. Hibridni model neuronske mreže baziran na radijalnim funkcijama projektovan je za potrebe modeliranja MLS-a u (Qina, 2015). Upravljačka logika sistema u mogućnosti je da upravlja levitacionim procesom i da obezbedi precizno praćenje željenog signala pozicije levitacionog objekta. Može se zaključiti iz prethodno navedenih radova da sistemi koji uključuju tehnike inteligentnog upravljanja unutar njihovih upravljačkih logika mogu da obezbede bolje upravljačke performanse u poređenju sa konvencionalnim kontrolerima bez upotrebe inteligentnih struktura.

Kao glavni parametar evaluacije će se, za potrebe eksperimentalnih ogleda u ovom poglavlju disertacije, koristiti maksimalna distanca (razdaljina) između dve levitacione pozicije tokom dvopozicionog levitacionog procesa. Upotrebljeni levitacioni sistem poseduje LQ (*linear quadratic*) upravljačku logiku praćenja željene pozicije levitacionog objekta. Logika praćenja željene pozicije će biti modifikovana korišćenjem i implementacijom ortogonalne neuronske mreže unutar postojeće upravljačke logike. Na taj način će biti napravljen pokušaj poboljšanja dvopozicione levitacije Inteco MLS-a po pitanju obezbeđivanja većeg maksimalnog pozicionog pomeraja od onoga koje pružaju druge upotrebljene upravljačke logike.

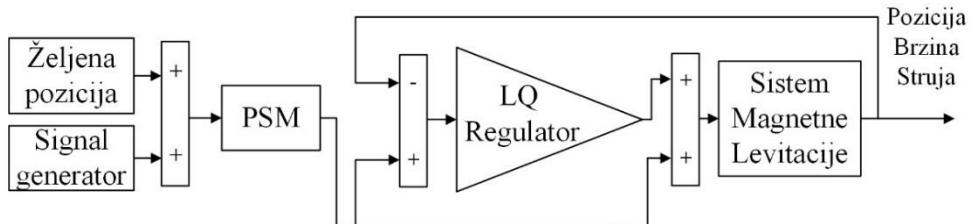
### 5.2.1 LQ upravljanje i implementacija standardnih neuronskih mreža u upravljačku logiku magnetnog levitacionog sistema

Standardni linearni kvadratni regulator je upotrebljen za postizanje stabilne dvopozicione levitacije objekta. LQ regulator se može koristiti kada su stanja sistema direktno merljiva. Često se koristi za praćenje zadatih trajektorija, što će i biti od glavnog interesa za ovo istraživanje. Takođe, veoma je efikasan pri stabilizaciji sistema u zatvorenoj spredi. LQ regulacija se bazira na minimizaciji kvadratne kriterijumske funkcije. Upravljački zakon LQ kontrolera se može izraziti kao:

$$u(t) = -Kx(t) = (-R^{-1}B^T P(t))x(t), \quad (5.2.1)$$

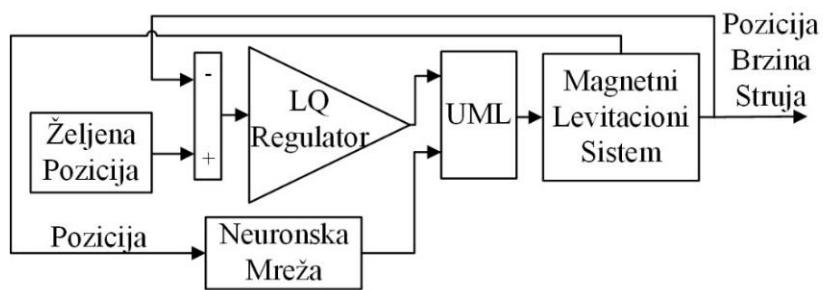
gde je  $R$  matrica koja definiše upravljačke ulazne težine kriterijumske funkcije,  $B$  je ulazna matrica modela u prostoru stanja,  $P(t)$  je rešenje Riccati-jeve diferencijalne jednačine i  $K$

predstavlja vremenski zavisno pojačanje povratne sprege. LQ regulator radi na takav način da izračunava vrednosti brzine levitacionog objekta, struje namotaja magneta i upravljačkog signala u svakom zadatom vremenskom trenutku  $t$ . Levitacioni objekat magnetnog levitatora je metalna lopta mase 57,1 g. Blok dijagram sistema sa LQ regulatorom prikazan je na slici 5.1. Dodatne informacije o upotrebljenom sistemu mogu se naći u (Internet dokument, 6).



Slika 5.1 Blok dijagram sistema zasnovanog na LQ upravljanju

Signal generator blok sa slike 5.1 može proizvesti jedan od tri različita tipova signala: sinusni, kvadratni i testerasti. Odabrane vrednosti amplitude i frekvencije unutar signal generator bloka određuju karakteristike željenog pobudnog signala sistema. Za periodu kvadratnog signala odabрано je  $T = 4\text{s}$ , dok su za amplitude generisanih signala birane vrednosti  $A_1 = 10^{-4}\text{m}$  i  $A_2 = 10^{-3}\text{m}$ . Puls sa modulacijom (PSM) blok se koristi za generisanje ekscitatornih pulseva koji se dovode na LQ regulator. U okviru upravljačke strukture sa slike 5.1 implementirana je standardna neuronska mreža. Blok dijagram modifikovanog levitacionog sistema prikazan je na slici 5.2.



Slika 5.2 Blok dijagram sistema sa integrisanim neuronskom mrežom

UML blok sa slike 5.2 predstavlja srednju vrednost sume trenutnih vrednosti izlaza LQ regulatora i neuronske mreže:

$$U_{ML} = \frac{U_{LQ} + U_{NN}}{2}, \quad (5.2.2)$$

gde je  $U_{ML}$  vrednost upravljačkog signala koji se dovodi na MLS ulaz,  $U_{LQ}$  je upravljački signal na izlazu LQ kontrolera, i  $U_{NN}$  je upravljački signal na izlazu neuronske mreže. Za proceduru projektovanja neuronske mreže iskorišćena je nelinearna autoregresivna mreža sa eksternim ulazima (NARX mreža). NARX tip mreže je upotrebljen usled dosadašnjih dobrih rezultata koje je pružio u radu sa Inteco MLS-om (Internet dokument, 6; Antić, 2013; Nikolić, 2016a).

Obavljena su dva tipa eksperimenata na sistemu čije su upravljačke logike prikazane na slikama 5.1 i 5.2. Realizovane su tri različite upravljačke logike za svaki eksperiment. Prva je standardna LQ upravljačka logika (Slika 5.1). Druga i treća upravljačka logika su gotovo identične i bazirane su na modifikovanoj logici sa slike 5.2. Razlikuju se jedino po tipu implementirane aktivacione funkcije unutar mreža. Sigmoidna aktivaciona funkcija (5.2.3) je iskorišćena u drugoj upravljačkoj logici, a hiperbolična tangentna funkcija (5.2.4) je iskorišćena za realizaciju treće logike. Obe aktivacione funkcije su opisane u (Sahin, 2012).

$$y(x) = \frac{1}{1 + e^{-x}}, \quad (5.2.3)$$

$$y(x) = \frac{2}{1 + e^{-2x}} - 1. \quad (5.2.4)$$

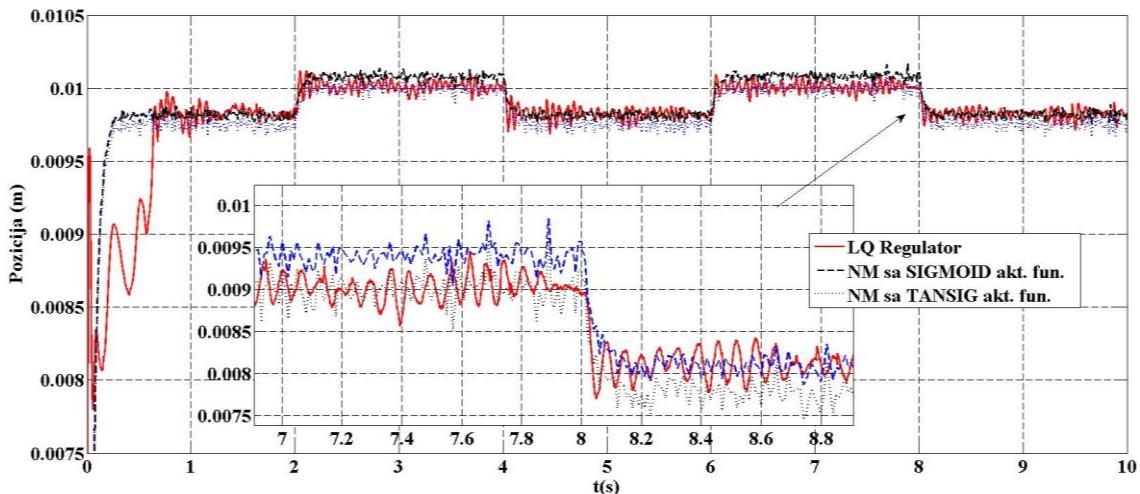
Mreža je trenirana upotrebom realnih eksperimentalnih podataka dobijenih radom levitacionog sistema. Vrednosti struje sa elektromagnetskih namotaja su izabrane za ulazne podatke. Vrednosti pozicije koje metalna lopta ima u pojedinačnim trenucima vremena su iskorišćene za izlaze mreže. Ulagani i izlagani signali su uzorkovani na svaku  $1ms$  za vremenski period od  $20s$ . Na osnovu toga, rezultujući ulagani i izlagani trening vektori su sadržali po 20000 elemenata. Tip treninga je odabran empirijskim testiranjem. Mreža je testirana najčešće upotrebjavanim tipovima treninga koji se nalaze unutar Matlab softverskog paketa. Najbolje performanse (najmanje srednjekvadratne greške) su dobijene kada je upotrebljen osnovni Quasi-Newton metod treninga. Ovaj metod je optimizacioni algoritam bez ograničenja koji poseduje brzu konvergenciju. Jedna iteracija ažuriranja težina mreže za vreme odabranog trenažnog procesa može se predstaviti na sledeći način:

$$\omega_i^{k+1} = \omega_i^k + \alpha^k d^k, \quad (5.2.5)$$

gde je  $d^k$  parametar pravca čija je svrha aproksimacija Njutnovog pravca,  $\alpha^k$  je veličina inkrementa koraka,  $\omega_i^k$  i  $\omega_i^{k+1}$  su vrednosti težinskih koeficijenata  $\omega_i$  u iteracijama  $k$  i  $k+1$ , respektivno. Parametar pravca  $d^k$  se može dobiti iz:

$$d^k = -B^k \nabla f(\omega^k), \quad (5.2.6)$$

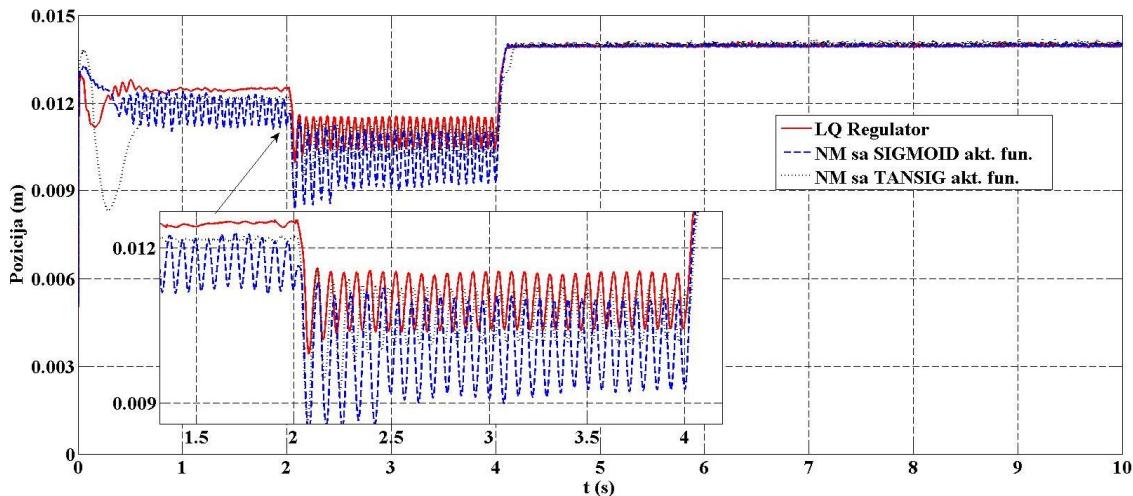
gde je  $B^k$  pozitivno definitna matrica koja se podešava iz iteracije u iteraciju. Petnaest neurona je iskorišćeno za formiranje skrivenog sloja neuronske mreže. Za postavku prvog eksperimenta upotrebljena je perioda signala  $T = 4s$  i vrednost amplitude (pomeraja)  $A_l = 10^{-4}m$ . Definisana amplituda predstavlja željeni pomeraj levitacionog objekta – distancu između prve i druge levitacione pozicije. Eksperimentalni rezultati procesa levitacije lopte (za vremenski interval  $t = 10s$ ) prikazani su na slici 5.3. Sa slike se može zaključiti da je dvopoziciona levitacija lopte ostvarena za sva tri slučaja. Oscilacije u svim slučajevima su do 1% u odnosu na željenu poziciju, što je zadovoljavajući rezultat. Nepravilnosti za vreme prve sekunde se isključuju iz analize pošto su izazvane ljudskim faktorom (pozicioniranje lopte u levitacionom prostoru se ostvaruje ručno).



Slika 5.3 Poređenje dvopozicione levitacije za tri različite upravljačke logike – zadati pomeraj  $A_l = 10^{-4}m$

Identične upravljačke logike su iskorišćene i za drugi eksperiment. Jedina promena je vrednost željenog pozicionog pomeraja lopte tokom dvopozicione levitacije. Vrednost pomeraja je sada postavljena na  $A_2 = 10^{-3}m$ , što je povećalo željeni pomeraj u poređenju sa prvim eksperimentom 10 puta ( $A_2/A_l = 10$ ). Lošije performanse nakon povećanja željenog pomeraja se mogu lako uočiti sa slike 5.4. Sistem gubi kontrolu nad levitacionim objektom za sve tri upravljačke logike nakon prve periode ( $T = 4s$ ). Izgubljena kontrola je prouzrokovala prekid levitacije lopte (pozicija y ose približno jednaka  $0.014m$ ). Takođe je očigledno sa slike 5.4 da je prisustvo oscilacija značajno veće u odnosu na one koje su se javljale u prvom

eksperimentu. Sistem nije sposoban da samostalno uspostavi kontrolu lopte ponovo, pa se drugi eksperiment završio neuspešno.



Slika 5.4 Poređenje dvopozicione levitacije za tri različite upravljačke logike – zadati pomeraj  $A_2 = 10^{-3} \text{ m}$

Predstavljeni eksperimenti su ponovljeni u više iteracija, međutim, dobijeni rezultati se nisu značajnije razlikovali. Generalno se može zaključiti da standardna i modifikovane upravljačke logike mogu zadovoljavajuće kontrolisati levitaciju lopte kada je zadati pomeraj maksimalne vrednosti  $10^{-4} \text{ m}$ . Loše upravljačke performanse i nezadovoljavajući rezultati su dobijeni za sve tri upravljačke logike za zadati pomeraj od  $10^{-3} \text{ m}$ . U narednom potpoglavlju će za rešavanje ovog problema biti realizovana nova neuronska mreža bazirana na ortogonalnim funkcijama.

## 5.2.2 Realizacija ortogonalnih polinoma za potrebe formiranja neuronske mreže

Pozitivan uticaj ortogonalnih mreža na stabilnost sistema u zatvorenoj spredi detaljno je prikazan u (Zou, 2009). Standardne aktivacione funkcije neuronskih mreža iz potpoglavlja 5.2.1 će u ovom istraživanju biti zamjenjene novom ortogonalnom trigonometrijskom funkcijom (Nikolić, 2016b):

$$\varphi(t) = e^{-t} \sin t. \quad (5.2.7)$$

Kompletan matematički aparat koji opisuje ovaj tip ortogonalnih trigonometrijskih polinoma prikazan je u (Nikolić, 2016b). Osnovna ideja novog istraživanja biće pronađak

ortogonalne funkcije koja će implementiranjem u okviru neuronske mreže obezbediti poboljšanu dvopozicionu levitaciju lopte. U tu svrhu će eksperimentalno biti upotrebljeni generalizovani kvazi-ortogonalni polinomi reda  $k=1$  (Nikolić, 2016a). Ovi polinomi predstavljaju generalizaciju prethodno primenjenih kvazi-ortogonalnih polinoma u (Antić, 2012a; Milojković, 2013). Njihova primena kroz prethodna istraživanja bila je opravdana iz dva razloga. Prvi razlog je taj što je razmatrani MLS tehnički nesavršen sistem (Danković, 2009b; Milojković, 2010; Antić, 2012a; Antić, 2012b) gde ovaj tip polinoma ima veliku upotrebnu vrednost, i drugi, što ortogonalni polinomi imaju stabilizacionu funkciju kada se koriste u obliku aktivacionih funkcija neuronskih mreža (Nikolić, 2016a).

Generalizovani polinomi Ležandrovog tipa su kombinacija tri klase polinoma: skoro ortogonalnih (Milojković, 2010; Antić, 2012b), poboljšanih ortogonalnih (Antić, 2012b) i kvazi-ortogonalnih Ležandrovih polinoma (Antić, 2012a; Milojković, 2015; Nikolić, 2016a). Oni su generalizovani i predstavljeni jednačinom (5.1.10) u okviru prethodnog potpoglavlja. Unutrašnji proizvod ortogonalnosti na intervalu  $(0,1)$  sa težinom  $w(x)=1$  je predstavljen jednačinom (5.1.15). Generalizovani kvazi-ortogonalni polinomi prvog reda ( $k=1$ ) na intervalu  $(0, 1)$  sa težinskim koeficijentom  $w(x)=1$  su prikazani u (5.1.12). Na osnovu tih jednačina realizovani su polinomi koji će biti iskorišćeni u ovom istraživanju:

$$\begin{aligned} P_1^{(1,\delta)}(x) &= a_{11}^{(1,\delta)}x + a_{10}^{(1,\delta)}, \\ P_2^{(1,\delta)}(x) &= a_{22}^{(1,\delta)}x^2 + a_{21}^{(1,\delta)}x + a_{20}^{(1,\delta)}, \\ P_3^{(1,\delta)}(x) &= a_{33}^{(1,\delta)}x^3 + a_{32}^{(1,\delta)}x^2 + a_{31}^{(1,\delta)}x + a_{30}^{(1,\delta)}, \\ &\vdots \end{aligned} \tag{5.2.8}$$

gde su:  $a_{11}^{(1,\delta)} = -1$ ,  $a_{10}^{(1,\delta)} = 1$ ,  $a_{22}^{(1,\delta)} = -\frac{(\delta+2)}{2}$ ,  $a_{21}^{(1,\delta)} = (\delta+1)$ ,  $a_{20}^{(1,\delta)} = -\frac{\delta}{2}$ ,  
 $a_{33}^{(1,\delta)} = -\frac{(\delta+3)(2\delta+3)}{6}$ ,  $a_{32}^{(1,\delta)} = (\delta+1)(\delta+2)$ ,  $a_{31}^{(1,\delta)} = -\frac{(\delta+1)(2\delta+1)}{2}$ ,  $a_{30}^{(1,\delta)} = \frac{\delta^2}{3}$ .

### 5.2.3 Projektovanje i primena ortogonalne neuronske mreže (ONN) na MLS. Eksperimentalni rezultati

Struktura neuronske mreže upotrebljene za realizaciju ONN identična je strukturama upotrebljenim u prethodnom potpoglavlju (sa jednim ulazom, 15 neurona u skrivenom sloju i jednim izlazom). Eksperimentalni rezultati primenjenih generalizovanih ortogonalnih polinoma (5.2.8) u vidu aktivacionih funkcija ONN predstavljeni su u tabeli 5.1. Procedura testiranja je izvršena odabirom vrednosti parametra  $\delta$  na opsegu 1.000-1.050 sa korakom 0.005. Tokom eksperimenta su sve zabeležene eksperimentalne performanse podeljene u četiri levitacione kategorije:

- Standardna levitacija (*average levitation*: AL) – performanse sistema odgovaraju rezultatima dobijenim primenom tri upravljačke logike iz potpoglavlja 5.2.1;
- Stabilizovana levitacija (*stabilized levitation*: SL) – kategorija kojoj odgovaraju poboljšane stabilizacione karakteristike jednopozicione levitacije;
- Bez levitacije (*no levitation state*: NLS) – levitacija lopte nije ostvarena (neuspšan eksperiment);
- Levitacija sa pozicionim pomerajem (*levitation with motions*: LWM) – poboljšana dvopoziciona levitacija lopte

Tabela 5.1 Eksperimentalni rezultati dobijeni na modelu MLS kada na sistem deluje NM sa implementiranim ortogonalnim aktivacionim funkcijama

Funkcija	Parametar $\delta$										
	1.000	1.005	1.010	1.015	1.020	1.025	1.030	1.035	1.040	1.045	1.050
$P_1^{(1,\delta)}(x)$	SL										
$P_2^{(1,\delta)}(x)$	AL										
$P_3^{(1,\delta)}(x)$	AL						NLS				
$P_4^{(1,\delta)}(x)$	LWM										

Rezultati iz tabele 5.1 pokazuju da aktivaciona funkcija bazirana na ortogonalnim funkcijama i određenim vrednostima parametra  $\delta$  pozitivno deluje na realizaciju i poboljšanje dvopozicione levitacije lopte. MLS iskorišćen u eksperimentalne svrhe je osetljiv na spoljašnje uslove i uticaje sredine. Zbog toga su se prilikom realizacije i ponavljanja eksperimenata javljali manji ili veći poremećaji snimljenih odziva i odstupanja od slučaja do slučaja. Ipak, najuspšnija dvopoziciona levitacija je ostvarena korišćenjem funkcije:

$$P_4^{(1,\delta)}(x) = a_{44}^{(1,\delta)}x^4 + a_{43}^{(1,\delta)}x^3 + a_{42}^{(1,\delta)}x^2 + a_{41}^{(1,\delta)}x + a_{40}^{(1,\delta)}, \quad (5.2.9)$$

gde je:

$$\begin{aligned} a_{44}^{(1,\delta)} &= -\frac{(\delta+2)(\delta+4)(3\delta+4)}{12}, \\ a_{43}^{(1,\delta)} &= \frac{(\delta+1)(\delta+3)(2\delta+3)}{2}, \\ a_{42}^{(1,\delta)} &= -\frac{(\delta+1)(\delta+2)(3\delta+2)}{2}, \\ a_{41}^{(1,\delta)} &= \frac{(\delta+1)(2\delta+1)(3\delta+4)}{6}, \\ a_{40}^{(1,\delta)} &= \frac{\delta^3}{4}. \end{aligned} \quad (5.2.10)$$

Funkcija  $P_4^{(1,\delta)}(x)$  je obezbedila poboljšanje dvopozicione levitacije metalne lopte za sve ispitane vrednosti funkcija. Eksperimentalno je pokazano da su najbolji rezultati u pogledu stabilnosti dobijeni za odabir parametra  $\delta$  na intervalu 1.000-1.020. Ovaj opseg parametra  $\delta$  je dalje ispitivan s ciljem preciznijeg utvrđivanja optimalnog rešenja. Izvršeni su novi eksperimenti sa implementiranom funkcijom  $P_4^{(1,\delta)}(x)$ , ali sada u okviru suženog intervala parametra  $\delta$  i sa korakom ispitavanja 0.002.

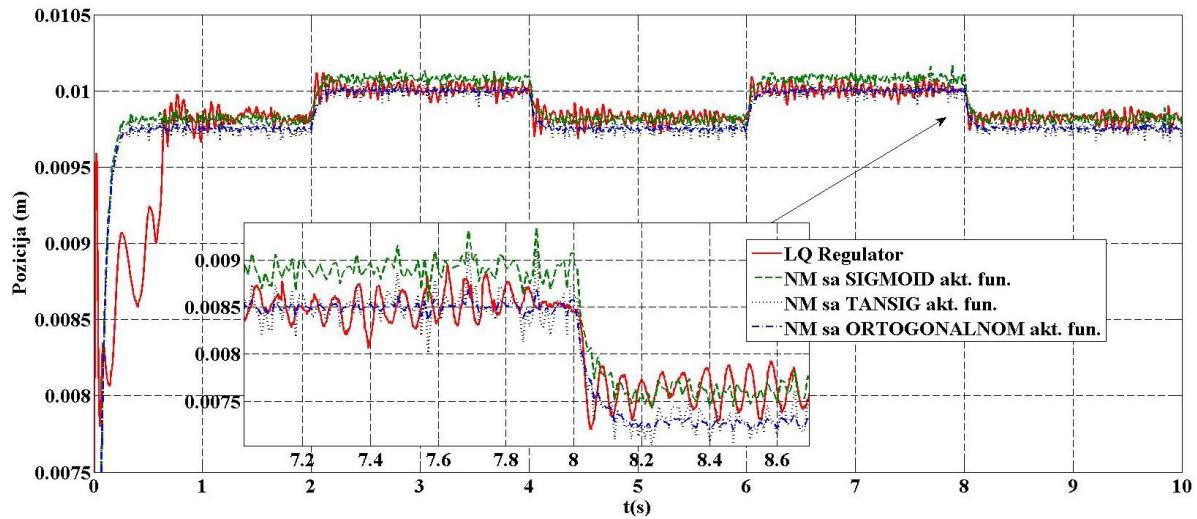
Najbolje performanse novih eksperimentalnih provera dobijene su za upotrebljenu vrednost  $\delta = 1.02$ , i u tom slučaju funkcija  $P_4^{(1,\delta)}(x)$  dobija konačnu formu:

$$P_4^{(1,\delta)}(x) = -8,9194x^4 + 20,4634x^3 - 15,4340x^2 + 7,2257x - 0,2653. \quad (5.2.11)$$

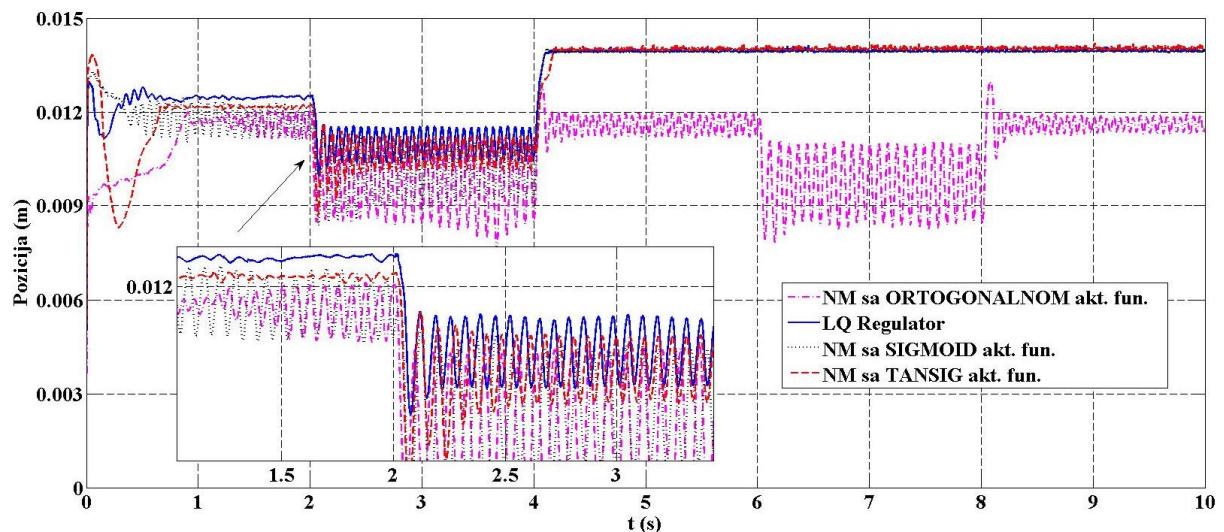
Nakon utvrđivanja optimalnog rešenja za odabir aktivacione funkcije obavljen je još jedan eksperiment i izvršena komparacija sa rezultatima drugih upravljačkih struktura dobijenih u prethodnom potpoglavlju (Slike 5.5 i 5.6). Slika 5.5 predstavlja rezultate prethodnih upravljačkih logika i projektovane ortogonalne neuronske mreže kada je zadati pomeraj između dve pozicije  $10^{-4} m$ . Može se zaključiti da ONN obezbeđuje slične rezultate kao i upravljačke logike prikazane u potpoglavlju 5.2.1.

Slika 5.6 predstavlja odgovarajuće komparacije eksperimentalnih rezultata kada je definisani pomeraj  $A_2 = 10^{-3} m$ . Lako se može zaključiti da jedino ONN obezbeđuje stabilno kretanje za povećani željeni pomeraj objekta tokom levitacije. Pojava velikih oscilacija je glavni primećeni nedostatak upotrebljene mreže. Oscilacije su u rangu 12,8% u poređenju sa idealnom donjom levitacionom pozicijom, što nije zadovoljavajući rezultat. Dalje, oscilacije su

do 2,5% na višoj levitacionoj poziciji, što je prihvatljivo. Ovi nedostaci će biti razmatrani kroz dalja naučna istraživanja u pokušaju da se oscilatornost levitacionog objekta minimizuje.



Slika 5.5 Poređenje dvopozicionih pomeraja lopte prikazanih na slici 5.3 i projektovane ONN bazirane na aktivacionoj funkciji iz (5.2.11) – za zadati pomeraj  $A_l = 10^{-4} \text{ m}$



Slika 5.6 Poređenje dvopozicionih pomeraja lopte prikazanih na slici 5.4 i projektovane ONN bazirane na aktivacionoj funkciji iz (5.2.11) – za zadati pomeraj  $A_2 = 10^{-3} \text{ m}$

# **6 Projektovanje endokrine neuronske mreže bazirane na postsinaptičkom potencijalu**

## **6.1 Endokrine neuronske mreže**

Proces kojim se različiti parametri biološkog sistema održavaju u okviru zadatih ograničenja naziva se homeostaza. Ovaj proces podrazumeva mehanizam negativne povratne sprege i za njegovo ostvarivanje i regulaciju zadužen je biološki endokrini sistem. Primer ovog biološkog procesa predstavlja regulacija nivoa šećera u krvi pomoću supstanci insulina i glukagona. Ovi hormoni utiču na promenu nivoa glukoze koja se koristi prilikom rada jetre. Dalje, jetra vrši proces konverzije glukogena, skladištenog u ćelijama masti, u glukozu koja se koristi za rad drugih ćelija. Drugi primer predstavlja kontrola ciklusa spavanja (kao odgovor na izloženost suncu) kod sisara, regulacijom izlučene koncentracije hormona melatonina.

Proces veštačke homeostaze sličan je biološkom procesu, ali u okviru sistema automatskog upravljanja. Primeri za to mogu biti regulacija temperature komponenti nekog sistema, regulacija potrošnje električne energije u cilju prevencije potpunog pražnjenja baterije, održavanje optimalnih vrednosti podesivih parametara sistema, itd. Veštački endokrini sistemi utiču na parametre sistema stimulacijama koje mogu biti prouzrokovane kako unutrašnjim stanjima sistema, tako i spoljašnjim stimulansima. Zbog toga su ovakvi endokrini sistemi vremenom postali i logična nadogradnja pojedinih veštačkih neuronskih mreža, čime se uticalo na efikasnija upravljanja i dugotrajnije autonomije upravljačkih dinamičkih sistema. Veštački izlučeni hormoni od strane realizovanog modela endokrinog sistema utiču na ponašanje individualnih neurona veštačke neuronske mreže. Ti neuroni predstavljaju zasebne ćelije unutar bioloških neuronskih sistema, uključujući sinapse, funkcije koje sumiraju ulaze neurona i izlaznu funkciju (koja je analogna funkciji aksona u ćeliji neurona). Da bi se omogućilo da veštačka ćelija reaguje na zadati nivo hormona, simuliraju se hormonalni receptori za svaki deo virtuelne ćelije. Ovi receptori su analogni onima u membrani bioloških neurona.

Implementacija veštačkih endokrinskih sistema unutar neuronskih mreža dovela je do realizacije endokrinskih neuronskih mreža (ENN). To je relativno novi tip neuronske mreže baziran na ideji imitacije veštačkih žlezdi i njihovog uticaja na neurone veštačke mreže. Veštačke žlezde su implementirane unutar neuronske mreže u (Timmis, 2009), čime je omogućena dodatna adaptivnost mreže na spoljašnje uslove. Metode za implementaciju

hormonalnih žlezdi mogu se primeniti na različite tipove standardnih neuronskih mreža, što je i pokazano u okviru radova (Timmis, 2010; Chen, 2014). Koncentracija hormona definiše se u zavisnosti od nivoa stimulacije žlezde. U biološkim sistemima, normalan nivo hormona je u najvećem broju slučajeva vrednost različita od nule. To ostavlja dve opcije za njihovu implementaciju u okviru veštačkih sistema: žlezde mogu konstantno da luče hormone pod normalnim uslovima, ili, može se smatrati da normalni uslovi podrazumevaju da nema lučenja hormona. U nastavku disertacije biće prikazana oba prilaza implementacije veštačkih žlezdi u okviru neuronskih mreža.

Stimulacija žlezde zavisi od uticaja okruženja i/ili internih parametara sistema. Žlezde generišu vremenski promenljive koncentracije hormona zavisno od stimulacije spoljašnje sredine. Implementacija hormona obavlja se po proceduri opisanoj u (Sauze, 2013), gde je izlaz jedinstvenog neurona ( $u$ ) sa  $n$  ulaza modelovan multiplikacijom težine  $\omega_i$  sa adekvatnom ulaznom vrednošću ( $X_i$ ), vrednošću koja predstavlja koncentraciju hormona ( $C_g$ ), osetljivošću sinapse hormona ( $S_j$ ) i, na kraju, izračunavanjem ukupne sume za sve ulaze neurona:

$$u = \sum_{i=1}^n \omega_i X_i C_g S_j, \quad (6.1.1)$$

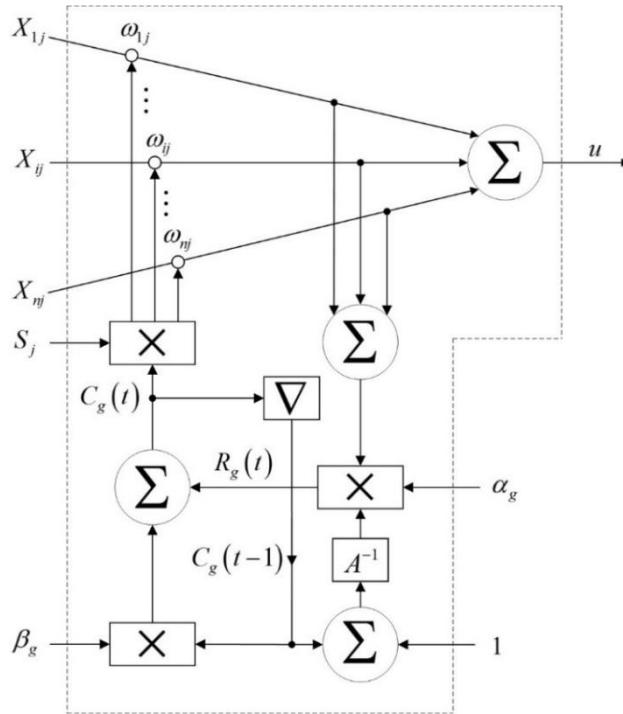
Promenljive  $i, j, i g$  iz (6.1.1) predstavljaju trenutni ulaz mreže, trenutni hormon i razmatranu žlezdu, respektivno. Jednačina (6.1.1) predstavlja izlaznu vrednost neurona sa implementiranim hormonalnim parametrima, pre primene aktivacione funkcije. Koncentracija hormona jedne žlezde se izračunava upotreboom formule iz (Timmis, 2010):

$$C_g(t+1) = \beta_g C_g(t) + R_g(t+1), \quad (6.1.2)$$

gde je  $\beta_g$  stopa lučenja,  $t$  odgovarajući vremenski uzorak i  $R_g$  stimulacioni parametar koji se može izraziti kao:

$$R_g(t) = \frac{\alpha_g}{1 + C_g(t-1)} \sum_j \omega_{ij}(t) X_{ij}, \quad (6.1.3)$$

gde je  $\alpha_g$  stopa stimulacije. Autori u (Timmis, 2010) predložili su jednačinu stimulacije (6.1.3) koja je zavisna od trenutne koncentracije hormona  $C_g(t)$ . Količina ispuštenog hormona u (6.1.1)-(6.1.3) reguliše se mehanizmom negativne povratne sprege koja sprečava sistem da postane prezasićen određenim hormonom. Implementacija hormonalnog procesa u okviru jednog sloja neuronske mreže, poštujući jednačine 6.1 - 6.3 predstavljena je slikom 6.1. Grafički blok sa oznakom  $\nabla$  predstavlja memorijski element sa kašnjenjem od jednog vremenskog intervala, a blok  $A^{-1}$  formira recipročnu vrednost ulaznog signala koji je doveden na sam blok.



Slika 6.1 Grafički prikaz procesa povezivanja hormona i sloja neuronske mreže

Poslednji nedefinisani parametar u jednačini 6.1.1 je parametar osetljivosti hormona  $S_j$ .

Parametar je definisan na opsegu  $(0, 1)$  u svim radovima koji su navedeni u ovom poglavlju. Ovaj opseg određuje hormonalni uticaj na mrežu u procentima između  $0\%$  i  $100\%$ . Ipak, očigledno je da je jednačina (6.1.1) jednaka  $0$  za  $S_j = 0$ . Kako bi se izbegla ta mogućnost, jednačina (6.1.1) se može modifikovati kao:

$$u = \sum_{i=1}^n \omega_i X_i (1 + C_g S_j). \quad (6.1.4)$$

Sada, kada je osetljivost  $S_j = 0$  u jednačini (6.1.4), neuronska mreža će funkcionišati kao standardna mreža na koju ne utiču žlezde:  $u = \sum_{i=1}^n \omega_i X_i$ . Što je veći parametar  $S_j$ , to će biti veći uticaj na neuronsku mrežu. Maksimalni hormonalni uticaj obezbeđen je za  $S_j = 1$ , u kom slučaju se jednačina (6.1.4) transformiše u oblik:  $\sum_{i=1}^n \omega_i X_i (1 + C_g)$ . Na primer, vrednost osetljivosti hormona u (Sauze, 2013) ručno je menjana za svaki eksperimentalni slučaj na vrednosti:  $0, 0.25, 0.50, 0.75$  i  $1$ . Ova procedura obezbedila je pet nivoa uticaja hormona na neuronsku mrežu. U narednom potpoglavlju biće projektovana prediktivna endokrina neuronska mreža sa novim načinom realizacije parametra osetljivosti endokrinog sistema.

## 6.2 Predikcija vremenskih sekvenci podataka upotrebom ortogonalnih endokrinih neuronskih mreža baziranih na postsinaptičkim potencijalima

Finansijsko tržište može se smatrati dinamičkim, nelinearnim i kompleksnim sistemom. Predikcija finansijskih parametara može biti zavisna od velikog broja nestacionarnih, nestruktuiranih i, ponekad, veoma haotičnih podataka. Mnogi parametri se karakterišu visokim stepenom promenljivosti i međusobnim korelacijama sa drugim parametrima sistema. Sve ovo čini zadatku uspešne predikcije znatno otežanim i dešava se da tradicionalne statističke metode nisu u mogućnosti da efikasno predvide željene vrednosti. Zbog toga su istraživači napravili veliki napor da prilagode veštačke neuronske mreže i upotrebe ih kao alat za bolji način procesiranja vremenski promenljivih podataka sa šumom. Dobre sposobnosti predikcije neuronske mreže su glavni razlog njihove primene na finansijskom tržištu. U ovom istraživanju biće projektovan novi tip neuronskih mreža za predikciju vremenskih sekvenci podataka.

Primer efikasnog modela neuronske mreže koji se koristi za predikciju vrednosti novčanih valuta predstavljen je u (Philip, 2011). Tačnost predikcije neuronske mreže sa normalizovanim *backpropagation* trenažnim procesom razmatran je u (Erdogan, 2014). Komparacija predikcionih performansi mreža sa promenljivim i konstantnim arhitekturama predstavljena je u (Zhang, 2001). Adaptivne tehnike upotrebljene u (Yu, 2005) iskorišćene su za prilagođavanje parametara učenja neuronske mreže. Parametri su automatski ažurirani praćenjem vrednosti signala pri promenljivim uslovima spoljašnje sredine. Projektovani model je učinio trenažni proces boljim, konvergenciju mreže bržom i doprineo je poboljšanju generalizacije podataka u odnosu na tradicionalne višeslojne mreže. U (Chen, 2008) predstavljen je hibridni model predikcije koji se koristi za predviđanje kursa novčanih valuta. Ovaj model je napravljen od tri pomoćne i jedne glavne mreže. Pokazano je da hibridni modeli mogu biti efikasniji od tradicionalnih statističkih metoda i jednostavnih neuronskih mreža. Fleksibilna neuronska mreža sa strukturom „drveta“ predstavljena je u (Chen, 2006). Ovakav model omogućio je selekciju ulaznih promenljivih, upotrebu različitih aktivacionih funkcija i uspostavljanje željenih konekcija među slojevima. Empirijski rezultati su pokazali da je predstavljeni model bolji od konvencionalnih mreža koje se koriste za predikciju podataka. Rad (Gomes, 2010) vrši evaluaciju upotrebnih vrednosti različitih aktivacionih funkcija u okviru neuronskih mreža. Rekurentna mreža, kroz koju podaci prolaze više puta tokom jedne trening iteracije, prikazana je u (Tenti, 1996). Ova mreža je demonstrirala impresivne sposobnosti učenja i predikciju kompleksnih skupova podataka. U radu (Pino, 2008) prikazan je još jedan

primer uspešne adaptivne neuronske mreže koja pruža bolje performanse od tradicionalnih mreža. Još jedan često korišćeni tip mreža za rešavanje problema predikcije je talasna (eng. *wavelet*) neuronska mreža (Božić, 2015). Prediktivni model, takođe baziran na talasnoj neuronskoj mreži, koristi se za predviđanje nelinearnih sezonskih vremenskih podataka u (Sa'Adah, 2015). U (Li, 2012) pokazano je da predikcija nelinearnih podataka može biti efikasnija upotreboom talasnih neuronskih mreža nego upotreboom tradicionalnih.

U ovom istraživanju biće predstavljan novi tip endokrine neuronske mreže (ENN) koji će se koristiti za potrebe predikcije podataka. Osnove ENN date su u potpoglavlju 6.1 ove disertacije. Osetljivost je jedan od glavnih parametara endokrinskih mreža i definiše uticaj hormona na neuronsku mrežu. Parametar osetljivosti je u radovima (Timmis, 2009; Timmis, 2010; Sauze, 2013; Chen, 2014) imao konstantnu unapred definisanu vrednost, tokom inicijalizacije mreže. U ovom istraživanju će biti napravljen korak dalje u razvoju ENN mreža. Akcenat će biti stavljen na razvoju samopodešavajućeg parametra osetljivosti uvođenjem postsinaptičkih potencijala unutar ENN strukture. Projektovani ENN model biće testiran serijom simulacija čiji je cilj predikcija dnevne vrednosti kursa tri svetske novčane valute. Ovaj predikcioni zadatak predstavlja dobar test slučaj usled visokog stepena nelinearnosti i promenljivosti ispitivane baze podataka tokom vremena.

### **6.2.1 Veštački endokrini sistemi i postsinaptički potencijali**

U potpoglavlju 6.1 prikazan je osnovni matematički aparat potreban za realizaciju veštačkog endokrinog sistema u okviru neuronske mreže. U dosadašnjim radovima parametar osetljivosti hormona  $S_j$  unapred je definisan tokom procesa projektovanja endokrine mreže. Za razliku od tih, već postojećih načina definisanja endokrinskih parametara, u ovom istraživanju će biti predstavljen novi metod za automatsko podešavanje parametra  $S_j$ . Podešavanje parametra biće bazirano na biološkim procesima ekscitacije i inhibicije. Ovi procesi karakterišu sinaptičke potencijale signala u biološkom nervnom sistemu. Inhibicija predstavlja sinaptički potencijal koji sprečava neuron da generiše puls (akcioni potencijal) koji će biti prenošen dalje kroz mrežu. Na drugoj strani, proces ekscitacije stimuliše neuron da generiše puls koji će preneti informaciju kroz mrežu aktiviranjem drugih neurona.

Motivacija za uvođenje postsinaptičkih potencijala unutar endokrinskih neuronskih mreža je dvostruka. Prvo, glavna ideja je realizacija nove metode ažuriranja parametara mreže koja će omogućiti dodatni stepen samoregulacije endokrine neuronske mreže. Drugo, modifikovana

mreža će posedovati sposobnost aktivacionog izoštravanja (*activation sharpening*) (French, 1991). Aktivaciono izoštravanje (Jian, 2009) je efikasna metoda redukovanja katastrofalnog zaboravljanja – fenomena zaboravljanja podataka od strane mreže kada se na nju dovode novi podaci. Katastrofalno zaboravljanje (Ans, 2000) je posledica preklapanja šablonu podataka unutar mreže. Cilj aktivacionog izoštravanja u ovom istraživanju je razvijanje poludistribuiranog predstavljanja podataka u izlaznom sloju neuronske mreže. Aktivacija neurona u izlaznom sloju je „izoštrena“ definisanjem jedne grupe neurona sa velikim aktivacionim vrednostima i smanjivanjem aktivacionih vrednosti drugih neurona. Povećanje i smanjenje aktivacionih vrednosti biće obavljeno uticanjem na težine izlaznog sloja, što će biti objašnjeno u narednom potpoglavlju.

## 6.2.2 Projektovanje ortogonalne endokrine neuronske mreže zasnovane na postsinaptičkim potencijalima (OENNPP)

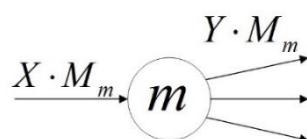
### 6.2.2.1 OENNPP struktura

*Backpropagation* (BP) algoritam učenja upotrebljen je kao osnova za projektovanje novog tipa endokrine neuronske mreže. BP tehniku učenja karakteriše to što na efikasan način obrađuje nepravilnosti i izuzetke među trening podacima. Takođe, veoma je popularna zbog brzine trenažnog procesa i jednostavnosti dizajna (Billings, 1991; Kumar, 1992). Novi OENNPP model biće projektovan korišćenjem standardnog BP algoritma kao osnove za nadogradnju. Neuronska mreža koja će biti korišćena u ovom istraživanju je standardna troslojna mreža i u nastavku sledi njen detaljni opis.

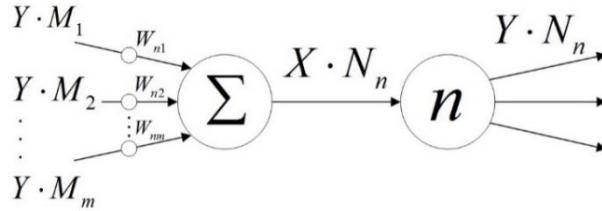
Prvi sloj mreže je ulazni sloj koji se sastoji od  $m$  neurona. Ulazni neuroni nisu procesne jedinice, pa zbog toga, izlaz svakog neurona u ovom sloju se izračunava kao:

$$Y \cdot M_m = X \cdot M_m, \quad (6.2.1)$$

gde su  $X \cdot M_m$  ulazne a  $Y \cdot M_m$  izlazne vrednosti neurona  $m$ . Drugim rečima, ulazni neuroni predstavljaju isključivo tačke prijema signala. Grafički prikaz ulaznog sloja dat je na slici 6.2.



Slika 6.2 Ulagani sloj neuronske mreže



Slika 6.3 Skriveni sloj neuronske mreže

Grafički prikaz skrivenog sloja dat je na slici 6.3. Ulagana vrednost svakog neurona u skrivenom sloju ( $X \cdot N_n$ ) izračunava se prema jednačini:

$$X \cdot N_n = \sum_{i=1}^m Y \cdot M_i \cdot W_{ni}, \quad (6.2.2)$$

gde je  $W_{ni}$  odgovarajući težinski koeficijent. Skriveni sloj je projektovan sa  $n$  neurona koji se aktiviraju pojedinačno upotrebo specijalno razvijenih ortogonalnih funkcija. Te funkcije su se dokazale kao uspešne u (Milojković, 2015; Nikolić, 2016a) po pitanju unapređenja performansi praćenja želenog signala, stabilizacije, povećanja preciznosti, aproksimacione sposobnosti, kao i zbog boljih karakteristika prilikom modeliranja dinamičkih sistema. Ipak, najvažniji razlog za njihovu upotrebu u ovom istraživanju je već projektovana prediktivna mreža bazirana na ortogonalnim funkcijama u (Perić, 2016). Ova mreža je upotrebljena za estimaciju vrednosti greške modeliranja u narednom vremenskom trenutku, što je uspešno iskorišćeno za unapređenje performansi testiranog nelinearnog sistema. Pošto je proces predikcije neuronske mreže glavni cilj i ovog istraživanja, nastavljena je upotreba ortogonalnih funkcija i za realizaciju OENNPP-a.

Prvi (6.2.3) i drugi (6.2.4) član sekvence u vremenskom domenu razvijenih generalizovanih ortogonalnih funkcija u (Nikolić, 2016a) su iskorišćeni kao aktivacione funkcije svih neurona u skrivenom i izlaznom sloju, respektivno.

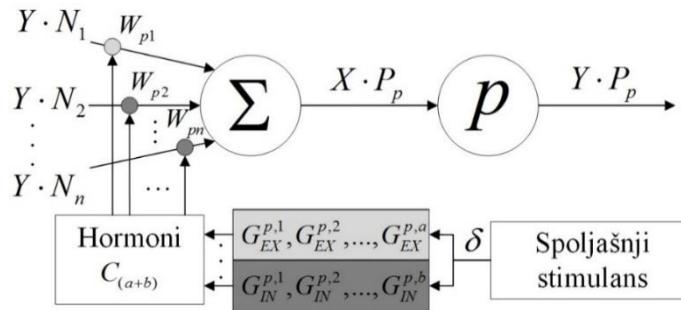
$$\varphi_1(t) = -e^{-t} + 1, \quad (6.2.3)$$

$$\varphi_2(t) = -\frac{(\delta+2)}{2}e^{-2t} + (\delta+1)e^{-t} - \frac{\delta}{2}. \quad (6.2.4)$$

Svaki neuron u skrivenom i izlaznom sloju u (Nikolić, 2016a) baziran je na aktivacionoj funkciji (6.2.4). Pokazalo se, nakon serije provera, da upotreba (6.2.3) za aktivacione funkcije skrivenog sloja i (6.2.4) za aktivacione funkcije izlaznog sloja, može značajno da redukuje ukupne proračunske troškove mreže. Struktura mreže, dobijena korišćenjem (6.2.3) umesto

(6.2.4) za neurone skrivenog sloja, primetno je uprošćena korišćenjem jednostavnije ortogonalne funkcije. Optimizovana struktura nije pokazala značajniji gubitak performansi predikcije, ali je u mnogome redukovano proračunsko vreme (što će biti pokazano kroz simulacione rezultate u ovom istraživanju). Adaptivni faktor  $\delta$  iz (6.2.4) baziran je na izračunavanju razlike između nominalnih i realnih spoljašnjih uticaja. Ovaj faktor je parametar blizak jedinicima kada postoji neka razlika između nominalnih i realnih uslova, ili jednak jedinicima kada su ovi uslovi jednaki. Konačno,  $\delta$  utiče na pojavu poremećaja ortogonalnosti (pojavu skoro i kvazi-ortogonalnosti), ali u veoma maloj meri da utiče na brzinu konvergencije realizovanog algoritma. Parametar može značajno uticati na konvergenciju samo za ekstremne varijacije  $\delta$ , što nije slučaj u ovom istraživanju.

Poslednji (treći) sloj OENNPP-a je izlazni sloj i predstavljen je na slici 6.4. Broj neurona u ovom sloju je  $p$ .



Slika 6.4 Izlazni sloj neuronske mreže

Ulagana vrednost svakog neurona u izlaznom sloju izračunava se, poštujući jednačinu 6.1.1, kao:

$$X \cdot P_p = \sum_{i=1}^n \left[ Y \cdot N_i \cdot W_{pi} \cdot C_{G_{EX}}^{p,a} \cdot S(G_{EX}^{p,a}; \delta, N_{EX}) + Y \cdot N_i \cdot W_{pi} \cdot C_{G_{IN}}^{p,b} \cdot S(G_{IN}^{p,b}; \delta, N_{IN}) \right], \quad (6.2.5)$$

gde je  $S(G_{EX}^{p,a}; \delta, N_{EX})$  funkcija koja determiniše osetljivost  $a$ -te ekscitatorne žlezde  $p$ -toga izlaznog neurona,  $S(G_{IN}^{p,b}; \delta, N_{IN})$  je funkcija koja određuje osetljivost  $b$ -te inhibitorne žlezde  $p$ -toga izlaznog neurona. Broj eksitatornih žlezdi koji ima uticaj na  $p$  težina neurona je označen kao  $a$  u  $G_{EX}^{p,a}$  (gde je  $G_{EX}$  oznaka za eksitatornu žlezdu). Slično, broj inhibitornih žlezdi koji je određen da ima uticaj na  $p$  težina neurona obeležen je sa  $b$  u  $G_{IN}^{p,b}$  (gde je  $G_{IN}$  oznaka za inhibitornu žlezdu). Dalje,  $W_{pi}$  je odgovarajuća izlazna težina,  $\delta$  je adaptivni faktor,  $C_{G_{EX}}^{p,a}$  je

koncentracija hormona  $a$ -te ekscitatorne žlezde  $p$ -tog neurona izlaznog sloja i  $C_{G_{IN}}^{p,b}$  je koncentracija hormona  $b$ -te inhibitorne žlezde  $p$ -tog neurona izlaznog sloja.

Procedura selekcije broja ekscitatornih ( $N_{EX}$ ) i inhibitornih ( $N_{IN}$ ) žlezdi, koje će biti korišćene unutar OENNPP-a, počinje izračunavanjem broja težina izlaznog sloja ( $N_{OLW}$ ):

$$N_{OLW} = N_{H_{LN}} \cdot N_{OUT}, \quad (6.2.6)$$

gde je  $N_{H_{LN}}$  broj neurona u skrivenom sloju, a  $N_{OUT}$  broj izlaza mreže. Dalje, može se izračunati ukupan broj žlezdi ( $N_{GL}$ ) koji će biti implementiran unutar neuronske mreže:

$$N_{GL} = \frac{N_{OLW}}{N_{AWG}}, N_{GL} \in N, \quad (6.2.7)$$

gde je  $N_{AWG}$  broj aktiviranih težina po žlezdi. Svaka eksitatorna ( $G_{EX}$ ) ili inhibitorna ( $G_{IN}$ ) žlezda pobudiće jednak broj težina izlaznog sloja. To će osigurati balansirano mapiranje signala koji se propagira do izlaza mreže.  $N_{AWG}$  se izračunava poštujući sledeći uslov:

$$N_{OLW} > N_{AWG} \geq 2. \quad (6.2.8)$$

$N_{AWG}$  mora da bude vrednost veća ili jednaka 2 pošto projektovana mreža podrazumeva implementaciju minimum dve žlezde (jedne eksitatorne i jedne inhibitorne). Dalje,  $N_{AWG}$  mora biti manji od  $N_{OLW}$  pošto se ne može implementirati više žlezdi nego što mreža poseduje težina u izlaznom sloju. Jedan težinski koeficijent može biti pod uticajem samo jedne endokrine žlezde. Poželjno je empirijski testirati različite kombinacije vrednosti parametara  $N_{GL}$ ,  $N_{EX}$  i  $N_{IN}$  koje se mogu dobiti poštujući uslove (6.2.6) – (6.2.8), za predloženu OENNPP strukturu. Empirijska analiza se sastoji od testiranja različitih OENNPP-a (za različite selekcije parametara  $N_{GL}$ ,  $N_{EX}$  i  $N_{IN}$ ) i odabirom mreže koja obezbeđuje najbolje performanse. Sa slike 6.4 može se zaključiti da eksitatorne i inhibitorne žlezde deluju na izlazne težinske koeficijente  $W_{p1} - W_{pn}$ . Kao što je ranije rečeno, svaka težina može biti pod uticajem jedne eksitatorne ili inhibitorne žlezde pa, na osnovu toga, sledi:

$$\begin{aligned} S(G_{EX}^{p,i}; \delta, N_{EX}) \neq 0 &\Rightarrow S(G_{IN}^{p,i}; \delta, N_{IN}) = 0, \\ S(G_{EX}^{p,i}; \delta, N_{EX}) = 0 &\Rightarrow S(G_{IN}^{p,i}; \delta, N_{IN}) \neq 0. \end{aligned} \quad (6.2.9)$$

### 6.2.2.2 OENNPP parametri

Glavna karakteristika OENNPP-a je uvođenje adaptivnog faktora  $\delta$  u težine izlaznog sloja mreže kroz uticaj postsinaptičkih potencijala. Ideja je imitiranje procesa iz prirode gde se ponašanje neurona reguliše pomoću hormona. Hormoni se luče od strane žlezda endokrinog sistema. U novoj mreži će hormoni biti lučeni od strane dva tipa žlezdi: ekscitatornih i inhibitornih. Razlog za uvođenje dva tipa žlezdi je u sledećem. Težine izlaznog sloja koje su pod uticajem  $S(G_{EX_j}; \delta, N_{EX})$  moraju imati veći uticaj na neurone izlaznog sloja u poređenju sa težinama koje su pod uticajem  $S(G_{IN_j}; \delta, N_{IN})$ . Predložena metoda bi trebala da efikasno ograniči propagaciju informacija od skrivenog sloja do izlaza mreže po pitanju aktivacionog izoštravanja signala. To bi dalje trebalo da redukuje količinu preklapanja memorisanih podataka u okviru mreže i da smanji pojavu katastrofalnog zaboravljanja. Da bi se to omogućilo, osetljivost  $S(G_{EX_j}; \delta, N_{EX})$  bi trebala da bude dominantna vrednost koja konvergira ka 1, dok bi  $S(G_{IN_j}; \delta, N_{IN})$  trebalo da bude mala vrednost koja konvergira ka 0 za veliki broj  $N_{EX}$ . Ako je vrednost  $S(G_{EX_j}; \delta, N_{EX})$  jednaka 1 za svaki odabrani broj  $N_{EX}$ , bilo bi slučajeva za neko  $N_{IN}$  kada osetljivost  $S(G_{IN_j}; \delta, N_{IN})$  ne bi bila mala vrednost koja adekvatno limitira propagaciju informacija. Jednačine (6.2.10) i (6.2.11) su definisane tako da obezbede opisane karakteristike osetljivosti i dodatno redukuju osetljivost parametra  $S(G_{IN_j}; \delta, N_{IN})$  za mreže sa malim brojem  $N_{IN}$ . Osetljivost svake ekscitatorne žlezde biće definisana na sledeći način:

$$S(G_{EX_j}; \delta, N_{EX}) = 1 - e^{-\delta \cdot N_{EX}}. \quad (6.2.10)$$

Funkcija  $S(G_{EX_j}; \delta, N_{EX})$  zavisi od uticaja parametra spoljašnje sredine  $\delta$  i broja eksitatornih žlezdi  $N_{EX}$ . Stimulansi  $\delta$  se direktno uvode u težine izlaznog sloja kao vid reakcije na varijacije nominalnih komponenti usled promene uslova rada. Kao što je već rečeno, stimulansi (vrednosti adaptivnog faktora) su jednak ili bliske 1. Jednačina (6.2.10) obezbeđuje da mreža sa malim brojem  $N_{EX}$  poseduje osetljivost svake eksitatorne žlezde u opsegu:  $0.63 \leq S(G_{EX_j}; \delta, N_{EX}) \leq 1$ . Dalje, osetljivost  $S(G_{EX_j}; \delta, N_{EX})$  je uvek jednaka 1 za mreže sa većim brojem  $N_{EX}$ . Na drugoj strani, osetljivost svake inhibitorne žlezde biće predstavljena kao mala pozitivna vrednost izračunata iz:

$$S(G_{IN_j}; \delta, N_{IN}) = \frac{S(G_{EX_j}; \delta, N_{EX})}{N_{IN}}. \quad (6.2.11)$$

Funkcija  $S(G_{IN_j}; \delta, N_{IN})$  zavisi od parametra spoljašnjeg stimulansa  $\delta$ , broja inhibitornih žlezdi  $N_{IN}$  i izračunate ekscitatorne osetljivosti  $S(G_{EX_j}; \delta, N_{EX})$ .

### 6.2.2.3 Procedura ažuriranja težinskih koeficijenata

Procedura ažuriranja težina izvršena je upotrebom signala greške. Cilj svakog trenažnog procesa je minimizacija dobijene greške (razlike željenog i realnog signala) na najmanju moguću vrednost. OENNPP funkcioniše u skladu sa principima standardnog BP algoritma (potpoglavlje 1.4.3), po kojima se težinski koeficijenti ažuriraju nakon svake iteracije. Greška, kao razlika željenih i dobijenih vrednosti, može se predstaviti u obliku:

$$E_{rr} = \sum_{i=1}^j (T_i - O_i)^2, \quad (6.2.12)$$

gde je  $j$  broj ulazno - izlaznih parova podataka, dok su  $T_i$  i  $O_i$  željene i dobijene vrednosti za  $i$ -ti razmatrani izlazni par, respektivno. Dalje, vrši se akumuliranje signala greške za svaki neuron tokom celog trenažnog procesa i ukupni signal greške se dobija sumiranjem svih individualnih grešaka. Ukupna greška se na kraju propagira unazad, po principima BP algoritma. Procedura ažuriranja težina skrivenog sloja izvršava se na osnovu (Rumelhart, 1986):

$$W_{nm(i+1)} = W_{nm(i)} + \Delta W_{nm(i)}, \quad (6.2.13)$$

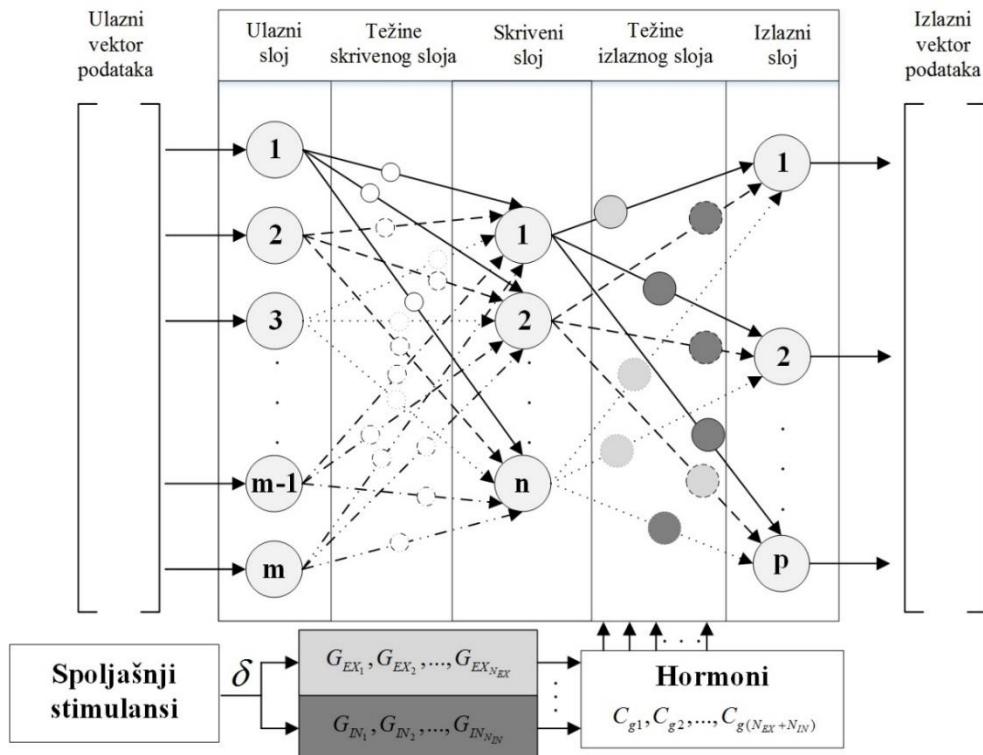
gde je  $W_{nm(i+1)}$  težina skrivenog sloja u  $i+1$  iteraciji,  $W_{nm(i)}$  je vrednost u  $i$ -toj iteraciji i  $\Delta W_{nm(i)}$  je promena vrednosti težine po uslovima BP algoritma. Procedura ažuriranja težina izlaznog sloja se takođe izvršava u skladu sa (Rumelhart, 1986), uz dodavanje uticaja postsinaptičkih potencijala:

$$W_{pn(i+1)} = W_{pn(i)} + \Delta W_{pn(i)} \cdot \left[ \Delta S(G_{EX_j}; \delta, N_{EX}) + \Delta S(G_{IN_j}; \delta, N_{IN}) \right], \quad (6.2.14)$$

gde je  $W_{pn(i+1)}$  vrednost težine izlaznog sloja u  $i+1$  iteraciji,  $W_{pn(i)}$  je vrednost u  $i$ -toj iteraciji,  $\Delta W_{pn(i)}$  je promena vrednosti težine po uslovima BP algoritma, a  $\Delta S(G_{EX_j}; \delta, N_{EX})$  i  $\Delta S(G_{IN_j}; \delta, N_{IN})$  su promene uticaja postsinaptičkih potencijala u zavisnosti od  $\delta$ . Ova dva uticaja se mogu definisati na osnovu (6.2.9) u sledećem obliku:

$$\begin{aligned}\Delta S(G_{EX_j}; \delta, N_{EX}) \neq 0 &\Rightarrow \Delta S(G_{IN_j}; \delta, N_{IN}) = 0, \\ \Delta S(G_{EX_j}; \delta, N_{EX}) = 0 &\Rightarrow \Delta S(G_{IN_j}; \delta, N_{IN}) \neq 0.\end{aligned}\quad (6.2.15)$$

Grafički prikaz projektovane OENNPP strukture dat je na slici 6.5. Promenljive  $G_{EX_{N_{EX}}}$  i  $G_{IN_{N_{IN}}}$  predstavljaju definisani broj ekscitatornih i inhibitornih žlezdi, respektivno. Promenljive  $C_{g_1}, C_{g_2}, \dots, C_{g(N_{EX}+N_{IN})}$  su izlučene koncentracije hormona za svaku žlezdu posebno. Svaka žlezda poseduje sopstvenu hormonalnu stopu. U sledećem potpoglavlju predstavljeni OENNPP biće upotrebljeni za rešavanje problema predikcije kursa novčanih valuta.



Slika 6.5 Generalizovana topologija OENNPP strukture

### 6.2.3 Simulacije na računaru i eksperimentalni rezultati

U cilju ispitivanja predložene OENNPP strukture biće izvršena serija predikcionih eksperimenata. Za potrebe formiranja trening baze podataka iskorišćeni su indeksi novčanih valuta američkog dolara u odnosu na tri druge valute: evra (EUR), britanske funte (GBP) i japanskog jena (JPY). Trening podaci iskorišćeni u ovom istraživanju su vrednosti navedenih valuta na dnevnoj bazi, i preuzeti su sa zvaničnog sajta Wharton škole Univerziteta u Pensilvaniji (Internet dokument, 8). Celokupna baza podataka obuhvata vremenski period od

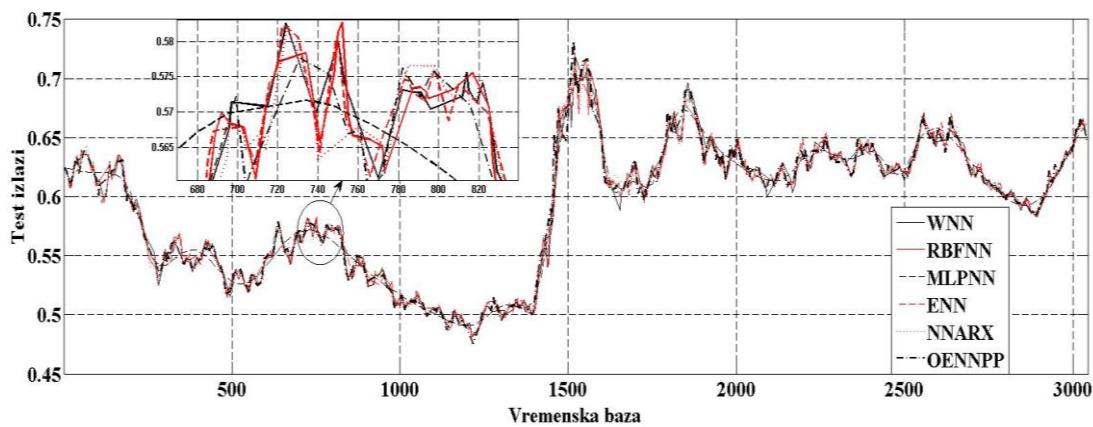
1. februara 2003. godine do 24. februara 2015. godine. Broj observacija svake valute je 3046, što implicira da rezultujući ulazni i izlazni vektori sadrže, svaki, po 9138 uzoraka (za tri praćene valute). Ukupna baza podataka je podeljena na tri jednakih skupa: trenažni, test i validacioni skup. Trening skup čini 70% podataka ukupne baze podataka, dok su trenažni i validacioni skupovi jednakih i sadrže po 15% od preostalih podataka. Test skup obezbeđuje nezavisnu meru performansi tokom i nakon treninga i on nema efekta na sam trenažni proces. Validacioni proces je izvršen na validacionom skupu i koristi se za merenje generalizacione sposobnosti mreže. Takođe, zadužen je i za okončavanje treninga kada generalizacija mreže prestane da konvergira. Originalna baza podataka, obrađena u simulacijama koje slede, može se preuzeti iz (Internet dokument, 8).

U eksperimentalne svrhe upotrebljeno je 6 neuronskih mreža sa sličnim strukturama. Predstavljena OENNPP mreža je formirana sa 5 ulaza i jednim izlazom. Odabrani ulazi su poslednjih 5 uzoraka ulaznog vektora. Broj neurona u skrivenom sloju odabran je prateći proceduru iz (Kaastra, 1996). Prvo, rad preporučuje obavljanje grube aproksimacije po pravilu geometrijske piramide, gde se broj neurona u skrivenom sloju može izračunati iz  $\sqrt{m \cdot p}$ , gde je  $m$  broj ulaza, a  $p$  broj izlaza mreže. Dalje, (Kaastra, 1996) predlaže dupliranje broja neurona sve dok se performanse mreže značajno unapređuju. Poštujući ta pravila, nakon završetka procesa probe i provere, najbolje performanse su dobijena za 16 neurona u skrivenom sloju. Broj trenažnih epoha postavljen je na 400 nakon završetka procedure treniranja i testiranja (Kaastra, 1996).

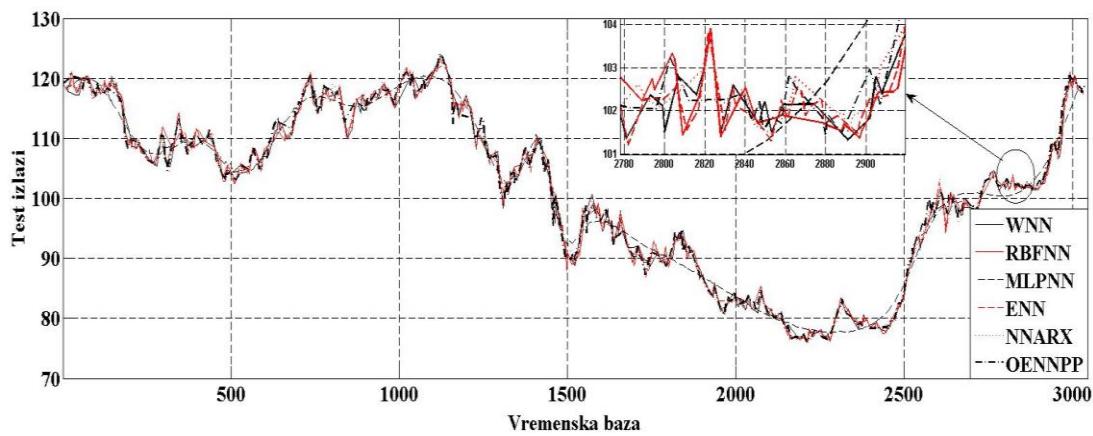
Na osnovu definisanog broja skrivenih neurona, broj težina izlaznog sloja za projektovanu strukturu je takođe 16. Poštujući jednačine (6.2.6) – (6.2.8) moguće je upotrebiti tri različite kombinacije para  $N_{GL} \times N_{OLW}$ , i to:  $2 \times 8$ ,  $4 \times 4$  i  $8 \times 2$ . Najbolje performanse mreže su dobijene za  $N_{GL} = 8$  ( $N_{EX} = 5$ ,  $N_{IN} = 3$ ) i gde, po takvom odabiru, svaka žlezda pobuđuje po dve izlazne težine. Uvedeno  $\delta$  je izračunato u realnom vremenu na osnovu razlike između godišnjeg proseka vrednosti zlata i vrednosti zlata za svaki uzorkovani dan. Dnevne vrednosti zlata (za obrađeni vremenski period) su takođe dobijene iz (Internet dokument, 8). Vrednost zlata je upotrebljena kao adaptivni faktor  $\delta$  pošto se zlato smatra najvažnijim dragocenim metalom koji ima uticaj na predikciju monetarnih parametara. Generalno, dragoceni metali se smatraju rezervnim valutama i poseduju izuzetan značaj na promene kursa novčanih valuta (Zhu, 2015).

Predloženi model OENNPP-a je testiran i rezultati su upoređeni sa 5 različitih tipova neuronskih mreža. Na taj način biće predstavljene performanse nove mreže u poređenju sa već

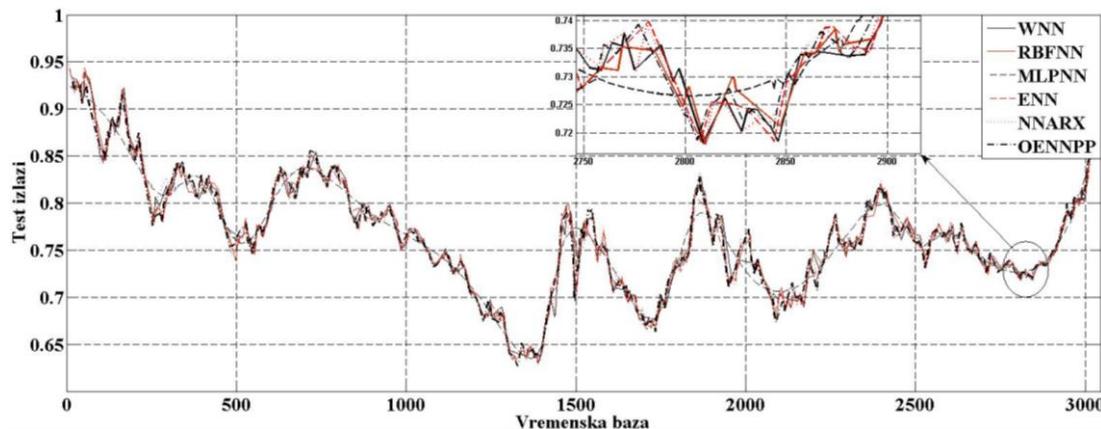
postojećim dobro poznatim prediktivnim modelima. Tipovi upotrebljenih mreža su: standardna endokrina neuronska mreža (ENN), autoregresivna neuronska mreža sa egzogenim ulazima (NNARX) kao tip dinamičke nelinearne mreže (Imandoust, 2010), talasna neuronska mreža (WNN), neuronska mreža sa radikalnom funkcijom (RBFNN) koja je opisana u (Lee, 1999) i višeslojna perceptronska neuronska mreža (MLPNN) predstavljena u (Gardner, 1998). Svih 6 upotrebljenih mreža poseduju sličnu troslojnu strukturu i realizovane su upotrebom Matlab softverskog paketa. Slike 6.6 – 6.8 daju grafički prikaz dobijenih predikcionih rezultata upotrebom navedenih modela.



Slika 6.6 Grafičko poređenje predikcije vrednosti novčane valute GBP  
upotrebom 6 modela neuronskih mreža



Slika 6.7 Grafičko poređenje predikcije vrednosti novčane valute JPY  
upotrebom 6 modela neuronskih mreža



Slika 6.8 Grafičko poređenje predikcije vrednosti novčane valute EUR upotrebom 6 modela neuronskih mreža

Tabela 6.1 prikazuje sumirane prediktive performanse svih 6 neuronskih mreža i obuhvata poređenje dobijenih vrednosti srednjekvadratnih grešaka (RMSE). Iz tabele se može zaključiti da su rezultati predikcije predloženog OENNPP modela za razmatrane novčane valute bolji u poređenju sa drugim testiranim mrežama. Poboljšanje preciznosti razvijenog OENNPP-a u poređenju sa standardnom ENN dolazi iz osobine nove mreže da poseduje dodatnu osjetljivost i adaptivnost na spoljašnje faktore. Drugi razlog za ostvarivanje boljih rezultata je uvođenje postsinaptičkih potencijala, koje je uticalo na obezbeđivanju dobrih karakteristika usled procesa aktivacionog izoštravanja.

Tabela 6.1 Srednjekvadratne greške različitih modela neuronskih mreža (RMSE)

Model	EUR		GBP		JPY	
	RMSE	Rang	RMSE	Rang	RMSE	Rang
OENNPP	<b>0.0000219</b>	<b>1</b>	0.0000161	2	<b>0.368</b>	<b>1</b>
ENN	0.0000443	2	0.0000201	3	0.405	2
NNARX	0.0002223	5	0.0000817	5	0.465	3
WNN	0.0001125	3	0.0000544	4	0.991	4
MLPNN	0.0745234	6	0.0111852	6	11.422	6
RBFNN	0.0001734	4	<b>0.0000127</b>	<b>1</b>	1.447	5

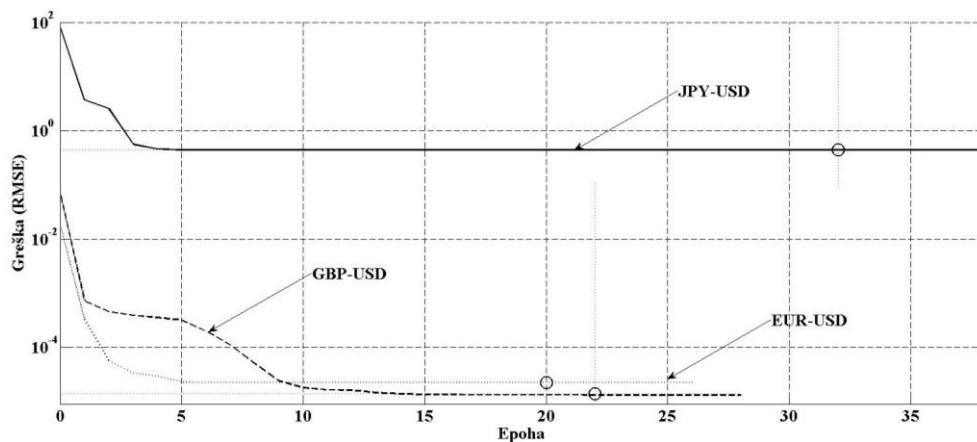
Glavna prednost predloženog modela je značajno smanjenje proračunskog vremena mreže u poređenju sa svim drugim testiranim modelima (Tabela 6.2). Unapređenje po pitanju proračunskog vremena dolazi iz karakteristike OENNPP-a da koristi ekscitatorne i inhibitorne žlezde koje obezbeđuju polu-distribuirani prenos podataka kroz model. Ovaj način podrazumeva efikasniji protok informacija kroz mrežu usled postojanja neaktivnih (ili skoro neaktivnih) grupa neurona u izlaznom sloju. Drugi razlog redukcije proračunskog vremena je upotreba jednostavne ortogonalne aktivacione funkcije (6.2.3) za neurone skrivenog sloja. Jednostavna funkcija je obezbedila brže procesiranje informacija skrivenog sloja OENNPP-a.

Direktno poređenje između OENNPP-a i ENN-a iz tabele 6.2 pokazalo je da unapređena ENN struktura u formi OENNPP-a smanjuje proračunsko vreme u svakom slučaju predikcije.

Tabela 6.2 Srednjekvadratne greške različitih modela neuronskih mreža (Proračunsko vreme)

Model	EUR		GBP		JPY	
	Proračunsko vreme (s)	Rang	Proračunsko vreme (s)	Rang	Proračunsko vreme (s)	Rang
OENNPP	<b>3.187</b>	<b>1</b>	<b>2.937</b>	<b>1</b>	<b>4.082</b>	<b>1</b>
ENN	8.492	5	6.705	4	9.320	6
NNARX	5.825	4	7.324	6	5.791	5
WNN	4.625	3	5.332	3	4.706	3
MLPNN	3.470	2	3.115	2	4.187	2
RBFNN	9.718	6	7.146	5	5.231	4

Na kraju će biti razmotrena i konvergencija projektovanog algoritma. Slika 6.9 prikazuje grafike grešaka tokom trenažnih procesa OENNPP modela. Algoritam je naučio GBP predikcione vrednosti nakon 22 epohe uz najmanju grešku  $1.6055 \cdot 10^{-5}$ . Dalje, mreža je konvergirala nakon 32 epohe sa greškom 0.3683 u slučaju JPY predikcionih podataka. Konačno, OENNPP je naučio EUR vrednosti i konvergirao nakon 20 epoha sa greškom  $2 \cdot 1936 \cdot 10^{-5}$ . Svaki trenažni proces je uključivao i validacionu proveru u cilju pronalaženja najboljih rezultata. Trening se završavao kada nije bilo dalje konvergencije nakon 6 uzastopnih validacionih provera.



Slika 6.9 Grafici grešaka OENNPP modela tokom trenažnog procesa

Na kraju, može se zaključiti da je realizacija samopodešavajućeg parametra osetljivosti uticala na veći stepen adaptacije neuronske mreže na uslove spoljašnje sredine. Zbog toga nova mreža poseduje povećani stepen adaptivnosti i upotrebljiva je kako u predikcione svrhe, tako i za upravljanje dinamičkim sistemima koji rade u okruženju sa promenljivim uslovima sredine.

## **7 Adaptivni endokrini ortogonalni ANFIS**

U ovom poglavlju će biti prikazan drugi način primene ortogonalnih polinoma i endokrinog faktora u okviru hibridnih inteligentnih sistema. U istraživanju će biti predstavljen novi metod modeliranja dinamičkih sistema modifikacijom tradicionalnog neuro-fazi sistema ANFIS-a. ANFIS (*Adaptive Neuro-Fuzzy Inference System*) predstavlja hibridnu inteligentnu strukturu mreže koja pruža odličnu kombinaciju performansi fazi logike i neuronskih mreža. Fazi logika obezbeđuje predstavljanje znanja na način razumljiv čoveku, dok neuronska mreža obezbeđuje sposobnost učenja i adaptacije na uslove spošlašnje sredine. Mnogobrojna naučna istraživanja hibridnih inteligentnih sistema uticala su na njihovu današnju popularnost. Ovakvi sistemi kombinuju različite tehnike inteligentnog upravljanja s ciljem sinteze njihovih pojedinačnih prednosti i minimizovanja nedostataka koje individualno poseduju (Medsker, 1995; Negnevitsky, 2005). Važno mesto među inteligentnim sistemima imaju hibridni neuro-fazi sistemi koji su bazirani na prirodnoj sinergiji neuronskih mreža i fazi logike (Nauck, 1997). Najpoznatiji tip neuro-fazi sistema, ANFIS, razvijen je krajem prošloga veka (Jang, 1993). U osnovi, ANFIS predstavlja neuronsku mrežu baziranu na Takagi-Sugeno fazi zaključivanju (skupovima fazi IF-THEN pravila).

Cilj ovog istraživanja biće pokušaj unapređenja klasičnog ANFIS-a implementacijom novih specijalno razvijenih kvazi-ortogonalnih funkcija u okviru poslednjeg sloja mreže. Implementacija novih funkcija podrazumeva njihovo korišćenje umesto standardnih Sugeno fazi pravila (konstantnih ili linearnih). U istraživanju će biti realizovane generalizovane kvazi-ortogonalne funkcije specijalno formirane da odgovaraju analizi i sintezi dinamičkih sistema. Velika prednost ovih funkcija je njihova efikasnost u radu sa varijacijama komponenti realnih sistema koje se javljaju usled promena uslova radnog okruženja (okoline) i koje se mogu uvesti u ANFIS u vidu hormonalnog efekta. Uvođenje hormonalnog efekta motivisano je savremenim istraživanjima u kojima je projektovan endokrini tip neuronske mreže (Timmis, 2009). Ovakve mreže imitiraju biološke procese regulacije ponašanja sistema lučenjem potrebnih koncentracija hormona. Hormoni se luče iz veštačkih žlezdi koje su implementirane u okviru njih. U radovima (Sauze, 2013; Chen, 2014) se pokazalo da je princip dodavanja veštačkih žlezdi primenljiv na različite tipove standardnih neuronskih mreža. U ovom istraživanju će biti predstavljena metoda implementacije endokrinog faktora i u okviru ANFIS-a. Projektovani unapređeni ANFIS – Ortogonalni Endokrini ANFIS (OEANFIS) biće upotrebljen za modeliranje laboratorijskog modela modularnog servo sistema. Servo sistem predstavlja dobro

eksperimentalno okruženje usled njegovih ugrađenih nelinearnosti i zavisnosti rada od varijacija u spošljašnjoj sredini.

## 7.1 Generalizovani ortogonalni polinomi

U istraživanju (Nikolić, 2016a) su upotrebljeni novi tipovi ortogonalnih funkcija i njihove generalizacije koje su prikladne za primenu u industrijskim aplikacijama (Danković, 2009b), u oblasti modeliranja (Milojković, 2010) i upravljanja dinamičkim sistemima (Nikolić, 2010). Matematički aparat i izvođenje potrebnih jednačina za realizaciju ovog poglavlja disertacije dato je u potpoglavlju 5.1.1.

## 7.2 Ortogonalni endokrini ANFIS (OEANFIS)

Standardni ANFIS je u osnovi neuronska mreža koja imitira Sugeno fazi model kod kojeg je skup fazi pravila generisan na bazi datih ulaznih i izlaznih skupova sistema. Tipično, Sugeno fazi pravilo ima sledeću formu:

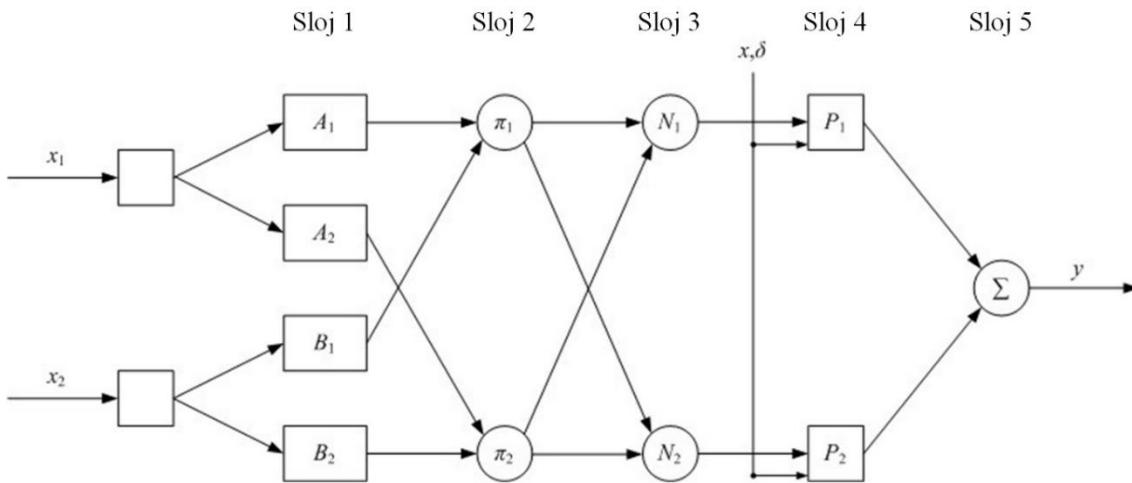
$$\begin{aligned}
 & \text{IF } x_1 \text{ is } A_1 \\
 & \text{AND } x_2 \text{ is } A_2 \\
 & \vdots \\
 & \text{AND } x_n \text{ is } A_n \\
 & \text{THEN } y = f(x_1, x_2, \dots, x_n),
 \end{aligned} \tag{7.1}$$

gde su  $x_1, x_2, \dots, x_n$  ulazne promenljive,  $A_1, A_2, \dots, A_n$  su fazi skupovi i  $y$  je konstanta ili linearna funkcija ulazne promenljive. U slučaju kada je  $y$  konstanta - Sugeno fazi model je nultog reda i fazi pravila su definisani singlonima (fazi skupovima sa funkcijama pripadnosti jednakim jedinicima u jednoj tački univerzalnog skupa i jednakim nulima na svim drugim mestima).

ANFIS je najčešće mreža sa propagacijom informacija unapred koja se sastoji od pet slojeva (Slika 7.1) (Jang, 1997). Eksterni ulazni signali se prvo propuštaju kroz fazifikacioni sloj za koji su u ovom istraživanju iskorišćene jednostavne aktivacione funkcije tipa zvona:

$$y_i = \frac{1}{1 + \left( \frac{x_i - a_i}{c_i} \right)^{2b_i}}, \tag{7.2}$$

gde je  $x_i$  ulaz, a  $y_i$  izlaz neurona  $i$  u sloju 1, dok su  $a_i$ ,  $b_i$  i  $c_i$  parametri aktivacione funkcije tipa zvona za taj neuron.



Slika 7.1 Struktura OEANFIS-a sa dva ulaza

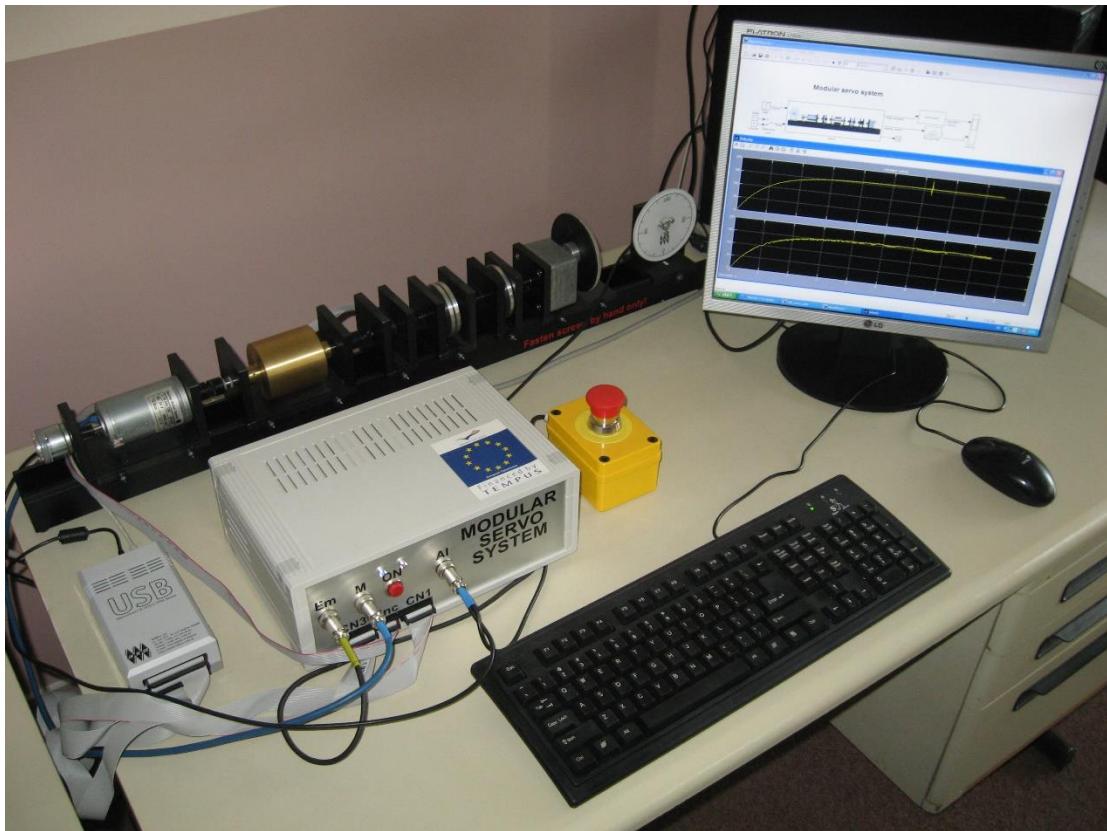
Svaki neuron u drugom sloju (sloju pravila) odgovara po jednom Sugeno tipu fazi pravila, poseduje funkciju za izračunavanje snage okidanja pravila kome pripada i baziran je na ulaznim vrednostima odgovarajućih fazifikacionih neurona. Konjukcija pravila je najčešće ostvarena operacijom množenja. Normalizovana snaga okidanja datog pravila (koja predstavlja doprinos datog pravila konačnom rezultatu) je izračunata pomoću neurona u trećem (normalizacionom sloju), baziranim na ulazima iz svih neurona sloja pravila.

Sledeći sloj je defazifikacioni sloj kod koga svaki neuron izračunava vrednost datog pravila kao konstantnu ili linearu kombinaciju ulaza sistema. Ovaj sloj je i najbitniji za ovo istraživanje. Glavna ideja je zamena singleton funkcija neurona ovog sloja ortogonalnim funkcijama opisanim u (Nikolić, 2016a; Nikolić, 2016b). Ove funkcije su specijalno realizovane za potrebe modeliranja dinamičkih sistema i trebale bi da obezbede bolje aproksimacione performanse uz smanjeno vreme treninga (pošto je potrebno trenirati samo jedan parametar umesto njih nekoliko kod standardnog ANFIS-a). Druga promena u odnosu na standardnu ANFIS strukturu je uvođenje adaptivnog faktora u neurone četvrtog sloja. Kao što je već pomenuto, objavljeno je nekoliko radova u prethodnim godinama koji se bave tematikom implementacije endokrine komponente u okviru standardnih neuronskih mreža. U radovima (Timmis, 2009; Sauze, 2013; Chen, 2014) hormoni su iskorišćeni za modifikaciju težina neurona u okviru mreža u zavisnosti od spoljašnjih uticaja. Cilj ovog istraživanja u disertaciji je uvođenje sličnog stimulusa direktno u neurone četvrtog sloja preko parametra  $\delta$  – kao reakcije na promene u komponentama dinamičkog sistema pod uticajem promenjenih uslova rada (zabeleženih preko senzora).

Peti, poslednji sloj mreže, poseduje jedan neuron (sumator) koji izračunava sumu izlaza svih defazifikacionih neurona s ciljem da proizvede konačni ANFIS izlaz. Na taj način cela struktura neuronske mreže imitira funkcionalnost Sugeno fazi modela sa jednom velikom prednošću – projektovani ANFIS ima mogućnost da vrši obuku parametara i da sam podešava svoje funkcije pripadnosti tokom trenažnog procesa. Za algoritam učenja i treniranja funkcija pripadnosti upotrebljena je kombinacija estimatora najmanjih kvadrata i metoda opadajućeg gradijenta (Jang, 1993). Svaka epoha u okviru ovog trening algoritma poseduje propagaciju informacija unapred i unazad. Ulazni vektor se prezentuje ANFIS-u tokom propagacije informacija unapred i izlazi neurona se izračunavaju sloj po sloj. Vrednosti grešaka se propagiraju unazad kroz mrežu i vrši se ažuriranje prethodnih vrednosti parametara. Standardni algoritam treninga (Internet dokument, 7) izvršava optimizaciju svih parametara mreže. Sposobnosti dobrog generalisanja i brze konvergencije ANFIS-a su veoma važne tokom *online* učenja i primeni u aplikacijama, posebno u onim gde je potrebna adaptivnost sistema (Zhang, 2010).

### **7.3 Modeliranje servo sistema korišćenjem OEANFIS-a**

Modularni servo sistem (Slika 7.2) iskorišćen je za potrebe modeliranja upotrebom projektovanog OEANFIS-a. Ovaj servo sistem (Internet dokument, 1; Antić, 2010) se, pored hardverskog dela, sastoji od softvera koji funkcioniše u okviru MATLAB okruženja i koji je pogodan za sprovođenje eksperimenata u realnom vremenu. Postavka servo sistema uključuje DC motor, mesingani teret, zazorni element, enkoder, magnetnu kočnicu, menjač brzine sa izlaznim diskom, tahogenerator i potenciometar. Elementi su redno vezani i montirani na metalnu šinu. Ugao rotacije osovine motora meri se pomoću inkrementalnog enkodera. RTDAC/USB akviziciona tabla sa A/D konvertorima omogućava komunikaciju samog uređaja i računara. Svim funkcijama akvizicione table se može pristupiti preko Modular Servo Toolbox-a koji je sastavni deo MATLAB/Simulink okruženja. Sistem poseduje nekoliko uključenih nelinearnosti (saturaciju, histerezis) koje su izazvane zazornim elementom, pojačavačem i aktuatorima. Varijabilni parametri servo sistema zavise za vreme rada uređaja i od promene uslova sredine (temperature i vlažnosti vazduha). Za potrebe ovog istraživanja biće razmatrane varijacije vrednosti temperature, detektovanih od strane temperaturnih senzora.



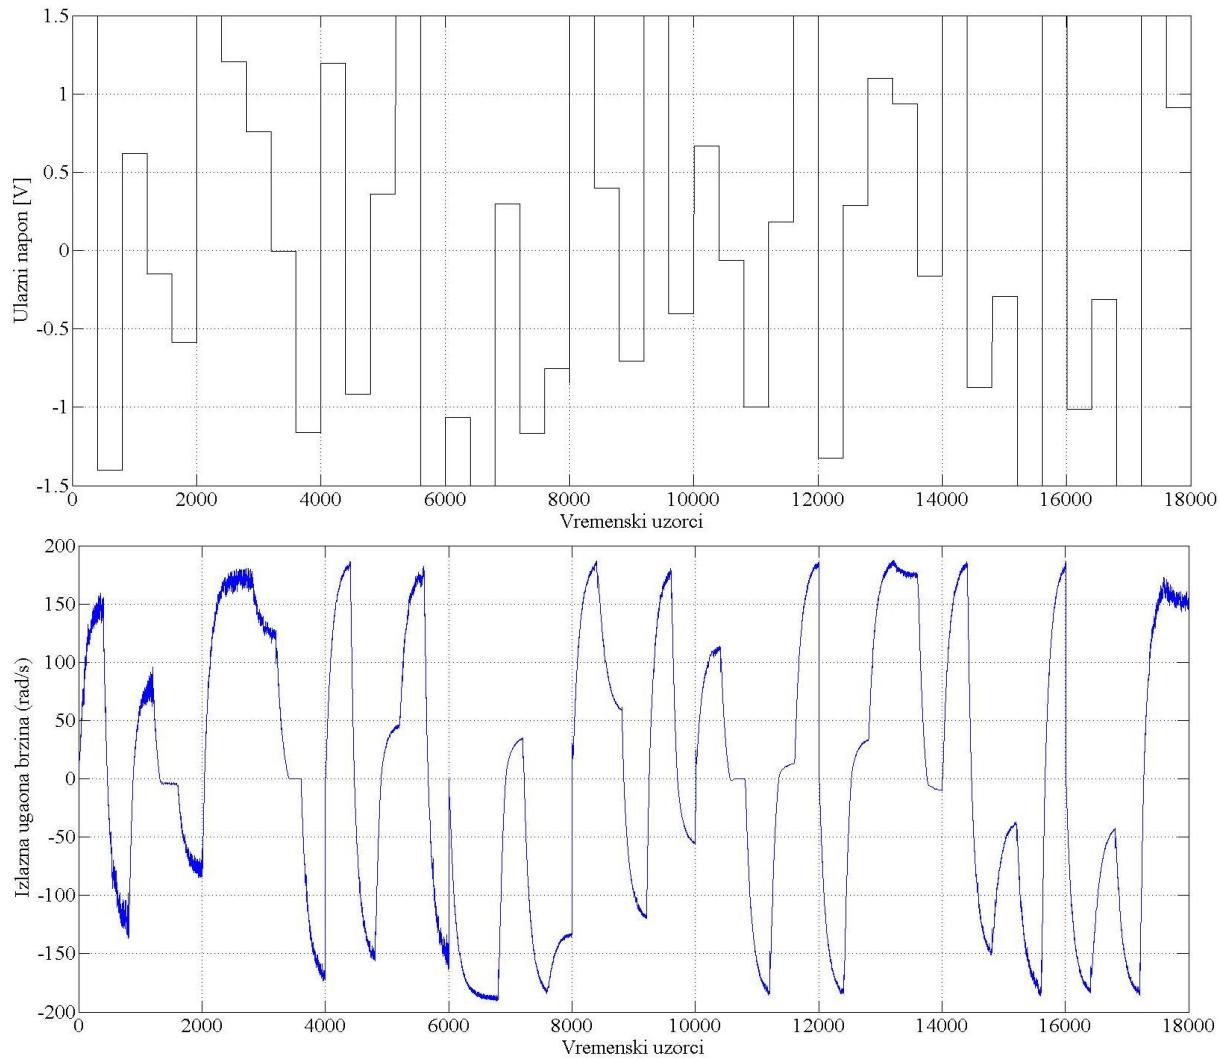
Slika 7.2 Postavka modularnog servo sistema

U cilju validacije performansi OEANFIS-a, sprovedene su simulacije rada modeliranog servo sistema pomoću nove mreže, standardnog ANFIS-a i ARX mreže (Autoregresivnog modela sa egzogenim ulazom) (Murray-Smith, 1997). Ulagani podaci (napon) i izlazni (ugaona brzina), zabeleženi za 180 sekundi rada realnog sistema, upotrebljeni su kao trening skupovi za neuronske mreže (Slika 7.3). Dovedeni ulagani napon je proizvoljno menjan na svake četiri sekunde, u rasponu od -1.5V do 1.5V. Ulagani i izlazni signali su uzorkovani na svakih 10ms, pa je svaki rezultujući vektor sadržao 18000 elemenata. Prva polovina podataka je iskorišćena za formiranje trening skupa podataka, dok je druga polovina upotrebljena za test podatke kojima će biti izvršena provera performansi svih mreža.

Upotrebljena ARX mreža smatra se linearnim modelom koji se može predstaviti u obliku:

$$y(k) + a_1 y(k-1) + \dots + a_m y(k-m) = b_1 u(k-d) + \dots + b_n u(k-d-n+1), \quad (7.3)$$

i definisana je pomoću tri parametra [m,n,d], vrednosti parametra  $a_i$  ( $i=1$  do  $m$ ) i parametra  $b_i$  ( $j=1$  do  $n$ ).



Slika 7.3 Ulazni i izlazni trening skupovi

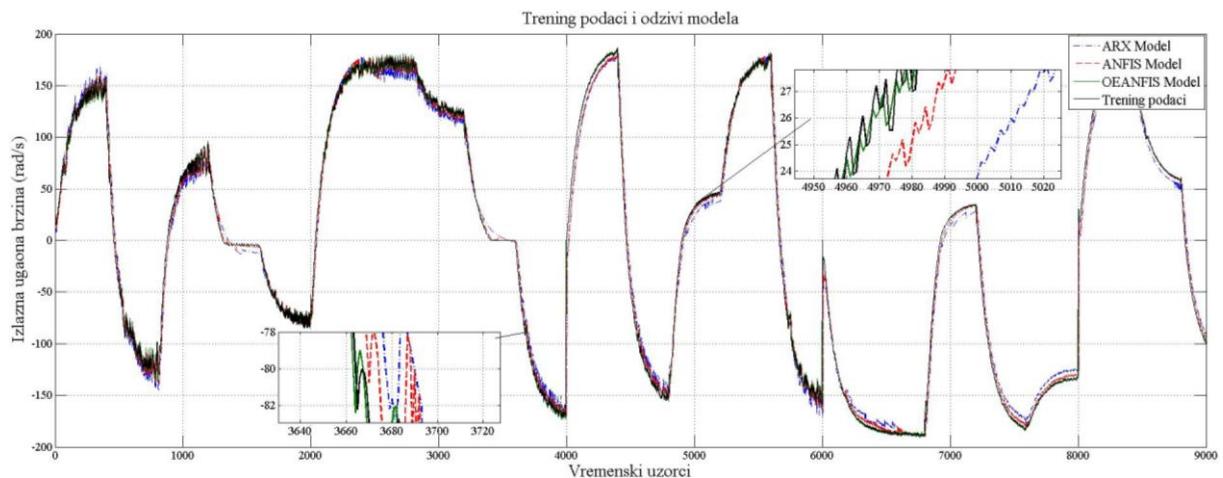
Za sva tri testirana modela odabrana su poslednja tri uzorka ulaznog signala i poslednja dva uzorka izlaznog signala, odnosno  $[m,n,d]=[2, 3, 0]$ . To je urađeno kako bi se izbeglo dobijanje kompleksnih i računski zahtevnih modela mreža. Najbolji skupovi parametara  $a_i$  i  $b_i$  su dobijeni korišćenjem MATLAB funkcije „arx“ koja automatski određuje najbolje vrednosti za ove parametre u zavisnosti od rezultata primenjene metode najmanjih kvadrata. ARX model je u osnovi linearni model i poseduje prednost u odnosu na druge dve testirane mreže usled brze identifikacije i aproksimacije zadatog modela. Nedostatak ove mreže je loša preciznost aproksimacije koju ona pokazuje pri modeliranju kompleksnijih sistema.

ANFIS model je realizovan korišćenjem MATLAB funkcije „genfis1“ uz primenu inicijalnog Sugeno fazi tipa treninga. Funkcija ima sledeću sintaksu za četiri ulazna argumenta: `genfis1(data, nummf, inputmf, outputmf)`, gde „`data`“ predstavlja skup ulaznih i izlaznih vektora, „`nummf`“ je broj funkcija pripadnosti po jednom ulazu neuronske mreže (po dve

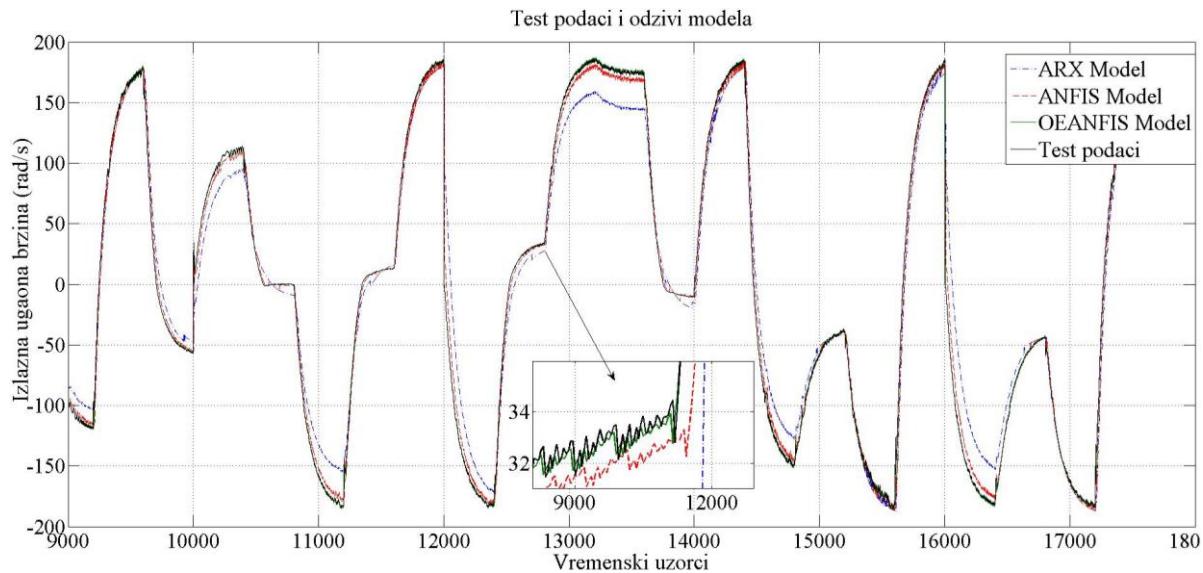
funkcije za svaki od pet ulaza), „inputmf“ predstavlja tip funkcije pripadnosti za svaki ulaz (upotrebljene su funkcije tipa zvona iz jednačine 7.2) i „outputmf“ određuje tip izlazne funkcije pripadnosti (za koji su odabrani konstantni tipovi funkcija). Trening neuronske mreže izvršen je korišćenjem MATLAB funkcije „anfis“. Ova funkcija koristi algoritam hibridnog učenja (kombinaciju najmanjih kvadrata i *backpropagation* metode opadajućeg gradijenta) za identifikaciju (treniranje) parametara funkcija pripadnosti u cilju modeliranja datog skupa ulazno/izlaznih podataka (prvih 9000 uzoraka snimljenog eksperimenta).

OEANFIS korišćen u eksperimentima je realizovan tako da ima ekvivalentnu strukturu ANFIS-u, uz dodatak implementiranih ortogonalnih funkcija u okviru neurona četvrtog sloja i implementiranog parametra  $\delta$  čije su vrednosti dobijene sa temperaturnog senzora. Parametar  $\delta$  je izračunat kao razlika normalnih (nominalnih) uslova sredine i onih realnih (trenutnih). Njegova vrednost je bliska jedinici ili jednaka jedinici pri nominalnim uslovima rada. Upotrebljena su četiri neurona u četvrtom sloju mreže, odnosno, implementirane su prve četiri ortogonalne funkcije iz jednačine (5.1.12).

Referentni izlazni signali i dobijene aproksimacije tri različita modela (ARX-a, ANFIS-a i OEANFIS-a) dati su na slikama 7.4 i 7.5. Može se videti da sva tri modela dobro aproksimiraju trening podatke (Slika 7.4) ali razlike postaju primetne sa aproksimacijom serije podataka za proveru performansi (Slika 7.5). Dok se OEANFIS odziv skoro poklapa sa željenim referentnim izlazom, druga dva modela zaostaju po pitanju preciznosti aproksimacije. Razlika kvaliteta aproksimacija po pitanju srednje kvadratne greške (RMSE) i vrednostima proračunskog vremena između tri testirana modela se može uočiti i iz komparativnih rezultata prikazanih u tabeli 7.1.



Slika 7.4 Trening podaci i odzivi modela



Slika 7.5 Test podaci i odzivi modela

Tabela 7.1 Komparativna analiza rezultata testiranih modela

Modeli	ARX	ANFIS	OEANFIS
Greška treniranja (RMSE)	12.9092	4.1669	3.4272
Greška testiranja (RMSE)	18.6473	7.4531	4.7119
Proračunsko vreme (s) (Intel – 3.30GHz, 8 GB RAM)	2.6668	17.1208	12.9306

Iz navedenih analiza može se zaključiti da je ARX modelu bilo potrebno najmanje vremena za obuku i aproksimaciju podataka, ali po cenu najmanje tačnosti. Za razliku od ARX-a, dva modela bazirana na ANFIS-u su zahtevala veća proračunska vremena za dostizanje bolje tačnosti. Drugim rečima, ukoliko je potreban brz model, treba iskoristiti ARX ili neku drugu jednostavnu neuronsku mrežu. Ukoliko je cilj tačnost aproksimacije, onda je ANFIS pravo rešenje. Poređenjem dva ANFIS modela može se videti unapređenje preciznosti kada se radi sa OEANFIS-om, što dolazi iz prirodne karakteristike ortogonalnosti da na dobar način utiče na kvalitet aproksimacije signala (suprotno od proizvoljnih singleton funkcija). Na drugoj strani, brže proračunsko vreme OEANFIS-a u odnosu na ANFIS dolazi iz potrebe da se nova mreža trenira ažuriranjem samo jednog parametra četvrtog sloja. Jedini nedostatak OEANFIS strukture se može ogledati u kompleksnosti samog modela. Još jedna važna prednost upotrebe ortogonalnih funkcija opisanih u ovom istraživanju je ta da ukoliko su poznati koeficijenti (težine) ortogonalnih funkcija, lako se može formirati funkcija prenosa modela sistema (Milojković, 2010).

## **8 Projektovanje hibridne strukture OENN- OEANFIS za podešavanje parametara PID regulatora**

U ovom poglavlju disertacije biće predstavljen način projektovanja i primene hibridne strukture endokrinih ortogonalnih neuronskih mreža. Hibridni sistem koji će biti razvijen baziran je na kombinaciji Ortogonalne endokrine neuronske mreže (OENN) i Ortogonalnog endokrinog ANFIS-a (OEANFIS) i predstavlja novu metodu za *online* optimizaciju PID (Proporcionalnog-Integralnog-Diferencijalnog) regulatora. PID upravljanje je široko korišćena tehnika za kontrolu rada industrijskih procesa i elektro sistema, kao i za održavanje stabilnog rada linearnih i nelinearnih sistema. Upotreba PID regulatora za kontrolu termičkih procesa prikazana je u (Song, 2016). Rezultati demonstriraju mogućnost upotrebe PID regulatora za efikasno redukovanje preskoka. U radu (Lavanya, 2015) opisano je ponašanje sistema sa dva rezervoara kada se pri upravljanju nivoom vode u njima upotrebljavaju PI, PD i PID regulatori. U (Mendoza, 2012) su predstavljene aplikacije bazirane na PID regulatorima koje se koriste za upravljanje kretanjem robota sa tri stepeni slobode. Eksperimentalni rezultati su demonstrirali efikasnost regulatora i jednostavnost podešavanja njegovih parametara tokom rada. Adaptivno PID upravljanje motorom sa permanentnim magnetima je opisano u (Jung, 2014). Cilj PID kontrole u (Maghsoudi, 2016) je brzo i precizno pozicioniranje tereta uz njegovo što manje osciliranje tokom kretanja. Ovaj rad je zanimljiv zbog upotrebe 3D laboratorijskog modela krana kao objekta upravljanja, pošto će isti objekat biti korišćen u istraživanju obuhvaćenim ovim poglavljem disertacije.

Pored tradicionalnih tehnika PID upravljanja mnogi istraživači su predlagali i različite tipove regulatora koji kombinuju PID i inteligentne tehnike upravljanja. Na primer, u (Shen, 2001) prikazana je fazi neuronska mreža za podešavanje PID regulatora koji se koristi za upravljanje sistemima koji na izlazima generišu odskočne odzive. Simulacioni rezultati su pokazali poboljšanje performansi i robustnosti sistema kada je inteligentno upravljanje implementirano u okviru tradicionalnog upravljanja. Drugi primer modela fazi neuronske mreže za podešavanje PID regulatora prikazan je u (Ho, 2006). Podešavanje PID parametara pomoću fazi logike obezbedilo je minimizaciju oscilacija i precizno praćenje referentnog signala. PID parametri u (Soyguder, 2009) su takođe dobijeni upotrebom fazi logike. Optimizacija tradicionalnog PID regulatora pomoću fazi logike izvršena je u cilju maksimizacije performansi sistema i unapređenja po pitanju smanjenja greške u ustaljenom

stanju. PID regulator nadgledan od strane ANFIS-a razvijen je u (Premkumar, 2015). Ovakav regulator je pokazao bolje performanse od ostalih testiranih regulatora tokom upravljanja DC motorom. Hibridna upravljačka tehnika koja uključuje PD upravljanje, ANFIS i fazi logiku predstavljena je u (Chen, 2013). Hibridno upravljanje je iskorišćeno za upravljanje robotskom rukom. ANFIS model je upotrebljen za inverznu kinematiku, dok je fazi logika iskorišćena za podešavanje PD parametara.

Radovi (Shen, 2001; Ho, 2006; Soyguder, 2009; Premkumar, 2015) su iskorišćeni kao osnova za razvoj novog tipa regulatora koji će kombinovati prednosti tradicionalnog PID regulatora i inteligentnih metoda. Adaptivni regulator, koji će biti predstavljen u ovom istraživanju, baziran je na ortogonalnoj neuronskoj mreži i ortogonalnom ANFIS-u. Obe mreže će biti realizovane uz implementaciju endokrinih faktora. Motivacija za korišćenje ortogonalnih neuronskih mreža potiče iz radova (Fang, 2000; Sher, 2001; Chen, 2004; Wang, 2009). Ove mreže su uspešno primenjene za preciznu aproksimaciju funkcija i pokazale su se kao veoma pouzdane i brze. Sastoje se od jednog skrivenog sloja pa su njihove odlike jednostavne topologije i mala proračunska vremena koja su im potrebna za obradu informacija. Konačno, ortogonalnost obezbeđuje izbegavanje lokalnih minimuma grešaka i smanjuje grešku aproksimacije sa povećanjem broja ekspanzionih elemenata mreže. Prihvatljivi tipovi ortogonalnih funkcija za primenu u okviru neuronskih mreža su najčešće Ležandrovi i Čebiševljevi polinomi prvog reda.

Razvoj i implementacija endokrinih faktora unutar struktura neuronskih mreža počeo je u prethodnih nekoliko godina. U (Timmis, 2009) predstavljen je adaptivni neuro endokrini sistem sa *online* učenjem. Glavna osobina ovog sistema je sposobnost obrade spoljašnjih informacija koje obezbeđuju adaptivnu meru sistema. Drugi tip neuro endokrinog sistema predstavljen je u (Chen, 2014). Pokazano je da ovaj tip sistema može biti efikasan u predikciji vremenskih sekvenci podataka. Endokrina neuronska mreža razvijena u (Sauze, 2013) pokazala se kao efikasna metoda za progresivnu promenu i sinhronizaciju ponašanja sistema sa eksternim događajima i faktorima, kao i za održavanje stabilnih unutrašnjih stanja upravljačkog sistema. Implementacija endokrinog faktora unutar strukture ANFIS-a je nova oblast istraživanja. Prvi put je ovakav sistem realizovan u (Milojković, 2015) u vidu ortogonalnog endokrinog ANFIS-a (OEANFIS-a). Način realizacije OEANFIS-a predstavljen je u 7. poglavlju ove disertacije. Postoje dve glavne razlike između projektovanog OEANFIS-a u tom poglavlju i OEANFIS-a koji će biti predstavljen u ovom. Prva je primena Čebiševljevih umesto Ležandrovih polinoma unutar strukture mreže. Druga razlika je u samom adaptivnom faktoru koji je doveden do neurona mreže. OEANFIS iz 7. poglavlja funkcioniše na taj način što se informacije iz

spoljašnje sredine direktno dovode kao stimulansi samoj mreži. Na drugoj strani, nova OEANFIS struktura biće pobuđena veštačkim spoljašnjim stimulansom. Ovaj stimulans je formiran u okviru pretprocesiranja podataka iz spoljašnje sredine pomoću OENN, gde nastaje kao izlazni signal neuronske mreže. Pretprocesiranje dolaznih podataka treba da izvrši prevenciju OEANFIS-a od loših proračuna usled prisustva poremećaja i promenljivih uslova spoljašnje sredine. U sledećem potpoglavlju biće detaljno predstavljena struktura i opisane karakteristike nove hibridne strukture.

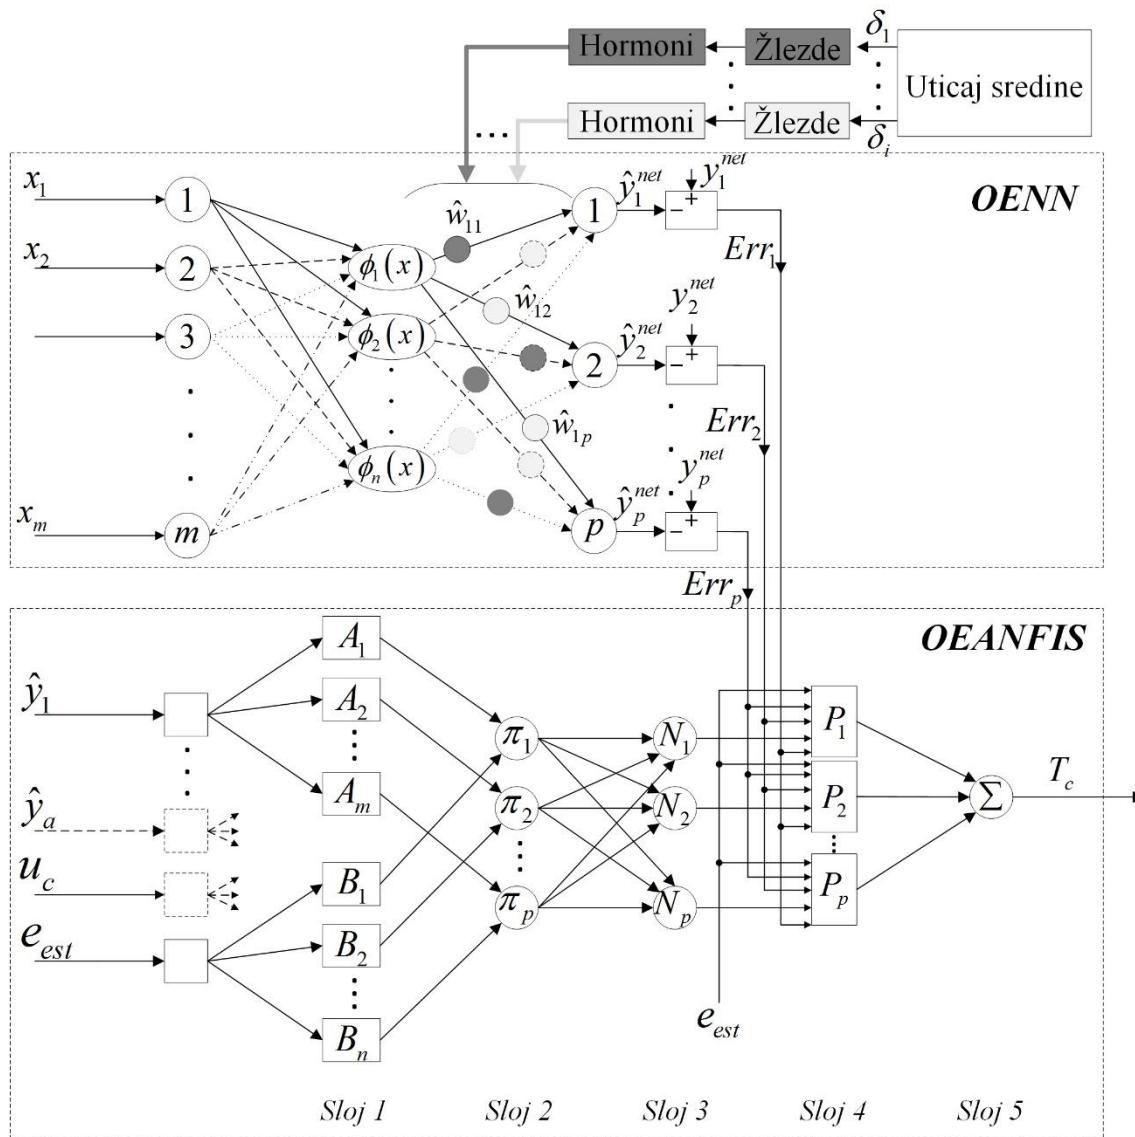
## **8.1 Konfiguracija OENN-OEANFIS hibridne strukture**

Kombinacija različitih inteligentnih metoda upravljanja unutar jednog upravljačkog sistema treba da obezbedi iskoriščavanje prednosti i minimizaciju individualnih nedostataka dva tipa mreže. Prednosti ANFIS-a su brza konvergencija, sposobnost implementacije željenih funkcija pripadnosti (Masood, 2012; Sankar, 2012), sposobnost primene prethodnog znanja, itd. Neuronske mreže su sposobne da procesiraju nelinearne i podatke sa šumovima, poseduju sposobnost učenja i generalizacije kao i robustnost na pojavu poremećaja. Na drugoj strani, one se mogu smatrati crnim kutijama i nisu u stanju da interpretiraju ulazno-izlazne korelacije na dobar način. Nedostaci ANFIS modela su njegova kompleksnost, nedostatak prilagodljivosti na podatke koji se razlikuju od onih naučenih tokom treninga i loše performanse predikcije pri pojavi individualnih pikova (Nayak, 2004). Ovo su i glavni razlozi za izbegavanje samostalnog korišćenja ANFIS strukture pri upravljanju visoko nelinearnim sistemima na koje deluju vremenski promenljivi poremećaji i devijacije.

Predloženi hibridni sistem će razdvojiti zadatke obrade podataka po sposobnosti koje poseduju mreže pojedinačno. Signali spoljašnjih poremećaja biće prvo obrađeni upotrebom OENN-a, a tek onda će procesirani signal biti uveden u OEANFIS kao veštački spoljašnji stimulans. Ova procedura bi trebala da pojača adaptivna pravila učenja OEANFIS-a i da obezbedi poboljšanu sposobnost nelinearnog procesiranja pod uticajem poremećaja. Hibridna struktura koja će biti korišćena za *online* podešavanje PID regulatora prikazana je na slici 8.1. Ulazi u OENN su postojeći referentni ulazi sistema ( $x_1, x_2, \dots, x_m$ ). Na drugoj strani, OEANFIS ulazi su signali ( $\hat{y}_1, \hat{y}_2, \dots, \hat{y}_a$ ) koji su dobijeni sa izlaza. OEANFIS poseduje dva dodatna ulaza  $u_c$  i  $e_{est}$  koji predstavljaju upravljački signal i estimiranu grešku sistema, respektivno. Izlazni signal OEANFIS-a ( $T_{PID}$ ) predstavlja *online* parametar podešavanja PID regulatora. Svi ovi

signali će detaljno biti objašnjeni u narednim potpoglavljkima. Predloženu strukturu je poželjno koristiti kada upravljačka logika i tradicionalni PID regulatori ne mogu da eliminišu poremećaje i devijacije željenog izlaznog signala.

Cilj projektovane OENN je prihvatanje i procesiranje signala poremećaja upravljačkog sistema. Ovi signali su uvedeni u mrežu u formi spoljašnjih uslova sredine (stimulansa sredine) i iskorišćeni za podešavanje težina mreže za potrebe aproksimacije referentnih ulaznih signala. Dalje, OENN izlazi su iskorišćeni za formiranje signala greške koji su uvedeni u OEANFIS u formi veštačkih spoljašnjih stimulansa. Veštački stimulansi utiču na proces zaključivanja fazi pravila i unapređuju izlazne vrednosti OEANFIS-a, što će biti kasnije i dokazano. Na kraju, OEANFIS izlazni signal je iskorišćen za adaptivno podešavanje PID regulatora.



Slika 8.1 Topologija OENN-OEANFIS strukture

### **8.1.1 Endokrina neuronska mreža**

Projektovanje endokrinih neuronskih mreža podrazumeva dodavanje ćelija veštačkih žlezdi unutar standardnih struktura mreža. Zadatak žlezdi je generisanje određenih koncentracija hormona koje zavise od stope uticaja spoljašnje sredine. Hormoni vrše uticaj na težinske koeficijente mreže multiplikacijom njihovih vrednosti sa vrednostima endokrinih faktora koje karakterišu svaku žlezdu. Veštački endokrini sistem je vremenski promenljiv, što ga čini ekstra osetljivim na spoljašnje poremećaje i uslove sredine. Struktura sa slike 8.1 poseduje sposobnost *online* učenja uz upotrebu spoljašnjih uticaja ( $\delta_1, \delta_2, \dots, \delta_i$ ) koji se koriste za aktivaciju veštačkih žlezdi. Matematički aparat kojim su definisani parametri izlaza neurona sa implementiranim endokriniim faktorom, koncentracije hormona pojedinačne žlezde i parametar stimulacije, prikazani su u okviru 6. poglavlja disertacije i jednačinama (6.1.1) – (6.1.4).

### **8.1.2 Ortogonalne funkcije**

Ortogonalni polinomi i funkcije predstavljaju matematički aparat za rešavanje brojnih problema upravljanja (Nikolić, 2010; Antić, 2012a; Nikolić 2016a; Perić, 2016). U radu (Nikolić, 2016b) autori su koristili ortogonalne polinome Ležandrovog tipa u vidu aktivacionih funkcija neuronske mreže. Takođe, novi tipovi ovih polinoma su razvijeni i primjenjeni tokom procesa realizacije OEANFIS-a u (Milojković, 2015). Ortogonalni polinomi koji će sada biti korišćeni su Čebiševljevi polinomi prvog reda (Abramovic, 1972). Razlozi upotrebe ovih polinoma i potreban matematički aparat objašnjeni su u potpoglavlju 5.1.2.

### **8.1.3 Struktura ortogonalne endokrine neuronske mreže**

Realizacija novog tipa hibridnog upravljanja motivisana je ostvarenim upravljačkim performansama laboratorijskog modela sistema protiv blokiranja točkova automobila iz (Perić, 2016). U radu su poboljšane performanse sistema dostignute razvojem takođe hibridnog inteligentnog upravljanja baziranom na novim tipovima endokrinih ortogonalnih neuronskih mreža. Struktura endokrine neuronske mreže koja će biti projektovana u ovom poglavlju bazirana je na Čebiševljevim ortogonalnim polinomima (5.1.19). Sposobnost ortogonalnih funkcija da aproksimiraju bilo koju nelinearnu funkciju poslužila je kao motivacija za

projektovanje OENN-a sa slike 8.1. Broj procesnih elemenata ( $\phi_1(x), \phi_2(x), \dots, \phi_n(x)$ ) koji će biti korišćeni u okviru strukture mreže određen je upotrebom strategije dinamičke ekspanzije (Yang, 1996). Svaki procesni element predstavlja jedan neuron buduće mreže (Slika 8.1). Koeficijenti mreže ( $w_i$ ) su jedinstveni pa su samim tim jedinstvene i težine ortogonalne neuronske mreže. Svi ulazi mreže su u potpunosti povezani sa procesnim elementima, kao što su i procesni neuroni vezani sa izlazima mreže. S obzirom da se radi o jednoslojnoj mreži, postoji samo jedan skup težina  $\hat{W}$  u okviru nje.

Endokrini faktor je implementiran u okviru mreže u formi uticaja sredine ( $\delta_1, \delta_2, \dots, \delta_i$ ). Svaki stimulans prouzrokuje hormonalni uticaj na mrežu uvođenjem određene vrednosti koncentracije hormona u težinske koeficijente mreže. Da bi se to uradilo, potrebno je znati karakteristike svih spoljašnjih uticaja koje će biti uvedene u mrežu i važno je odlučiti koliko će pojedinačni stimulans imati uticaja na ponašanje mreže. Uticaj stimulansa određen je parametrom osetljivosti  $S_i$  čija vrednost može biti u opsegu od 0 do 1. Svaki stimulans je predstavljen definisanim brojem veštačkih žlezdi koje su zadužene za regulaciju koncentracije hormona  $C_g$ . Broj žlezdi koji će biti korišćen u okviru mreže određen je metodom probe i greške. Generalno, prva proba se može izvršiti sa jednom žlezdom za svaki stimulans pojedinačno a broj žlezdi se progresivno povećava dok ne budu postignute željene performanse mreže.

Funkcija (5.1.22) se nakon uvođenja endokrinog faktora u neuronsku mrežu može predstaviti i u obliku:

$$y = F(X) = \sum_{i=1}^n (w_i C_g S_j) \phi_i(X) + R(X, n, C_g, S_j). \quad (8.1)$$

Adaptivni algoritam učenja OENN-a baziran je na metodi opadajućeg gradijenta (Hertz, 1991), gde je adaptivna komponenta obezbeđena hormonalnim uticajem na težine mreže. Nakon faze učenja, aproksimaciona greška ( $E$ ) OENN-a se može izračunati kao:

$$E = \hat{y} - \hat{y}^{net} = (W - \hat{W} C_g S_j)^T \phi + R, \quad (8.2)$$

gde  $W = [w_1, w_2, \dots, w_n]^T$  predstavlja vektor referentnih vrednosti težina,  $\hat{W} = [\hat{w}_1, \hat{w}_2, \dots, \hat{w}_n]^T$  je vektor koji sadrži trenutne vrednosti težina,  $\hat{y}$  je izmereni izlazni signal sistema i  $\hat{y}^{net}$  je izlaz sistema aproksimiran pomoću OENN. Metoda opadajućeg gradijenta zahteva izračunavanje izvoda kvadratne greške koja se može predstaviti kao:

$$J = \frac{E^2}{2}. \quad (8.3)$$

Konstanta jednaka  $1/2$  je uključena u (8.3) kako bi se poništio efekat eksponenta tokom procesa diferenciranja. Ova konstanta nema uticaja na dalje proračune pošto će tokom procesa treninga jednačina biti multiplikovana proizvoljnom stopom učenja, pa se njen uticaj može lako anulirati. Ekstremna vrednost  $J$  se izračunava kao:

$$\frac{\partial J(W - \hat{W}C_g S_j)}{\partial (W - \hat{W}C_g S_j)} = \frac{\partial \left( \frac{1}{2} E^2 \right)}{\partial E} \cdot \frac{\partial E}{\partial (W - \hat{W}C_g S_j)} = E\phi = 0. \quad (8.4)$$

Konačno, prema generalizovanom delta pravilu (Burrascano, 1991), adaptivni algoritam učenja imaće formu:

$$\frac{d(W - \hat{W}C_g S_j)}{dt} = \eta E\phi, \quad (8.5)$$

gde je  $\eta$  pozitivno pojačanje.

Predložena procedura ažuriranja težina optimizuje proces učenja favorizovanjem težina koje mogu imati pozitivan uticaj na procesiranje spoljašnjih stimulansa. Adaptivno učenje je aktivnije kada su intenzivni spoljašnji poremećaji i devijacioni izlazni signali. Adaptivno učenje tada optimizuje upravljanje pod dejstvom poremećaja nakon iterativnog procesa ažuriranja težina. Ažurirane težine postaju manje osetljive na spoljašnje faktore kada je uticaj spoljašnjih poremećaja minimizovan na željenu vrednost. Adaptivni algoritam učenja čini mrežu ekstra osetljivom na spoljašnje faktore i optimizuje upravljački sistem kako bi povećao robustnost i stabilnost sistema. Na kraju se OENN izlazi  $\hat{y}_i^{net}$  ( $i = 1, 2, \dots, p$ ) porede sa referentnim signalima  $\hat{y}_i$  i formiraju se signali greške:

$$Err_i = \hat{y}_i - \hat{y}_i^{net}. \quad (8.6)$$

Dobijeni signali greške predstavljaju formirane veštačke stimulanse sredine koji će biti uvedeni u četvrti sloj OEANFIS-a.

### **8.1.4 Struktura OEANFIS-a**

OEANFIS struktura koja je realizovana u ovom istraživanju sastoji se iz pet slojeva. Prva tri i peti sloj mreže su identični odgovarajućim slojevima već realizovanog OEANFIS-a iz sedmog poglavlja (potpoglavlje 7.2), tako da ovom prilikom neće biti ponavljan njihov opis. Jedina razlika dve strukture je u četvrtom sloju i on će sada biti detaljno predstavljen.

Četvrti defazifikacioni sloj ima funkciju izračunavanja posledične vrednosti datog pravila za svaki neuron posebno. Ova vrednost može biti linearna ili konstantna kombinacija vrednosti sistema. Standardne singleton funkcije ovog sloja su u istraživanju koje je obuhvatilo 7. poglavlje disertacije zamenjene Ležandrovim ortogonalnim polinomima. Dosadašnja istraživanja su pokazala da se u mnogim slučajevima može ostvariti veća preciznost aproksimacije upotrebom Čebiševljevih umesto Ležandrovih ortogonalnih polinoma. Zbog toga će novoprojektovani OEANFIS koristiti Čebiševljeve polinome predstavljene jednačinom (5.1.19). Druga važna karakteristika novoformiranog četvrtog sloja biće uvođenje veštačkih spoljašnjih stimulansa u sve njegove neurone. Svrha ovih signala je da obezbede OEANFIS-u procesirane signale devijacije sistema, na čiji kvalitet utiče uspešnost izvršene aproksimacije referentnog signal pomoću OEENN-a. Drugim rečima, ovaj stimulans predstavlja adaptivnu meru OEANFIS-a. Na primer, kada je poremećaj zanemarljiv, stimulans će konvergirati ka nuli pa će OEENN precizno aproksimirati željeni signal. U tom slučaju će OEANFIS funkcionisati kao standardni ortogonalni ANFIS. Na drugoj strani, uz prisustvo velikog poremećaja, OEENN neće biti u mogućnosti da aproksimira signal sa zadovoljavajućom tačnošću, pa će greška aproksimacije uticati na povećanju signala stimulansa.

Kao algoritam učenja OEANFIS-a korišćena je kombinacija metode opadajućeg gradijenta i estimacije najmanjih kvadrata (Jang, 1993). Trening algoritam se sastoji iz dva dela: propagiranja ulaznih informacija unapred i propagiranje grešaka unazad. Propagiranje informacija unapred podrazumeva dovođenje vektora podataka na ulaze OEANFIS-a, nakon čega se izlazi neurona izračunavaju sloj po sloj. Nakon toga se formira greška na izlazu mreže (razlika između željene i stvarne izlazne vrednosti) i primenjuje se *backpropagation* algoritam tokom propagacije vrednosti greške unazad. Svi parametri OEANFIS-a se tokom trenažnog procesa optimizuju na način koji je predstavljen u (Milojković, 2013).

### 8.1.5 Inicijalizacija OENN-OEANFIS strukture

<b>Pseudokod inicijalizacije OENN strukture</b>
1. Izabrati broj ulaza ( $m$ ) i izlaza ( $p$ )
2. Izabrati dimenziju Čebiševljevih elemenata ekspanzije ( $n$ ) prema strategiji dinamičke ekspanzije
3. Projektovati potpuno povezanu mrežu u zavisnosti od odabralih $m, p, n$
4. Odabratи broj stimulansa sredine ( $i$ )
5. Postaviti broj žlezdi ( $g$ ) za svaki stimulans sredine na $g = 1$
6. Proizvoljno izabrati vrednosti težinskih koeficijenata mreže
7. Postaviti inicijalnu koncentraciju hormona na: $C_g(0) = 0$
8. Postaviti vrednost konstante lučenja $\beta_g$ unutar opsega [0, 1]
9. Postaviti vrednost stope stimulacije $\alpha_g$ unutar opsega [0, 1]
10. Posebno definisati parametar osetljivosti svakog hormona ( $S_g$ ) unutar opsega [0, 1]
11. <b>For</b> $t = 1$ to MaxStep <b>do</b> %
11.1 <b>For</b> $l = 1$ to $g$ % ažuriranje parametara za svaku žlezdu
1) Izračunati $R_l(t)$ prema jednačini (6.1.3)
2) Izračunati $C_l(t+1)$ prema jednačini (6.1.2)
<b>End For</b>
11.2 <b>For</b> $i = 1$ to $p$ % izračunavanje izlaznih vrednosti mreže za svaki neuron posebno
1) Uvesti izmerenu vrednost signala $\hat{y}_i$ za $t$ -tu iteraciju
2) Izračunati vrednost aproksimiranog signala $\hat{y}_i^{net}(t)$ korišćenjem (8.1)
3) Izračunati grešku izlaza $Err_i$ prema (8.6)
4) Uvesti trenutnu vrednost $Err_i$ u OEANFIS: <i>Pseudokod inicijalizacije OEANFIS-a</i>
<b>End For</b>
11.3 Ažurirati težine mreže u skladu sa metodom opadajućeg gradijenta
<b>End For</b>
12. <b>When</b> $g = 0$ <b>then</b> $Err_i = Inf$
13. Definisati minimalnu vrednot konvergencije greške ( $E_{conv}$ ) % između dva uzastopna test slučaja
14. Nakon MaxStep iteracija: % određivanje optimalnog broja endokrinih elemenata

**If**  $Err_i^{g-1} - Err_i^g \geq E_{conv}$  %  $Err_i^g$  i  $t=1$  su  $Err_i$  strukture OENN sa  $g$  i  $g-1$  žlezdi, respektivno.

**then**

1) Povećati broj žlezdi za svaki stimulans za jedan:  $g = g + 1$

2) Vratiti se na korak 6

**else** Poboljšanje performansi više nije zabeleženo za zadato  $E_{conv}$ . Treba koristiti strukturu sa  $g-1$  žlezdi za svaki stimulans.

**End If**

#### Pseudokod inicijalizacije OEANFIS strukture

1. Izabrati broj ulaza  $a$
  2. Generisati dva dodatna ulaza  $a+1$  (za  $u_c$ ) i  $a+2$  (za  $e_{est}$ )
  3. Inicijalizovati fazifikacioni sloj. Odabratи broj fazi skupova za svaki definisani ulaz. Odabratи inicijalne vrednosti parametara  $a_i$ ,  $b_i$  i  $c_i$  za svaki neuron
  4. Inicijalizovati sloj pravila. Odabratи broj neurona  $p$
  5. Inicijalizovati normalizacioni sloj. Postaviti broj neurona na  $p$
  6. Inicijalizovati defazifikacioni sloj. Postaviti broj neurona na  $p$
  7. **For**  $t=1$  to MaxStep **do** %
    - 7.1 Izračunati izlaze fazifikacionog sloja
    - 7.2 Izračunati izlazne vrednosti sloja pravila
    - 7.3 Izračunati normalizacionu snagu okidanja ( $\bar{\mu}_i$ ) normalizacionog sloja za svako pravilo
    - 7.4 Izračunati izlaznu vrednost svakog defazifikacionog neurona po jednačini:  

$$P_i = \bar{\mu}_i \cdot C_i \cdot Err_i \cdot e_{est} \quad \% \text{ gde je } C_i \text{ posledični parametar}$$
    - 7.5 Izračunati vrednost izlaznog sloja: sumirati sve izlazne vrednosti neurona defazifikacionog sloja ( $P_i$ ) i generisati OEANFIS izlaz ( $T_c$ )
    - 7.6 Ažurirati parametre regulatora
    - 7.7 Primeniti metod opadajućeg gradijenta prilikom treniranja OEANFIS-a kao regularnog ANFIS-a (sa dodatkom koraka 7.4)
- End For**

## 8.2 Optimizacija PID parametara korišćenjem OENN-OEANFIS strukture

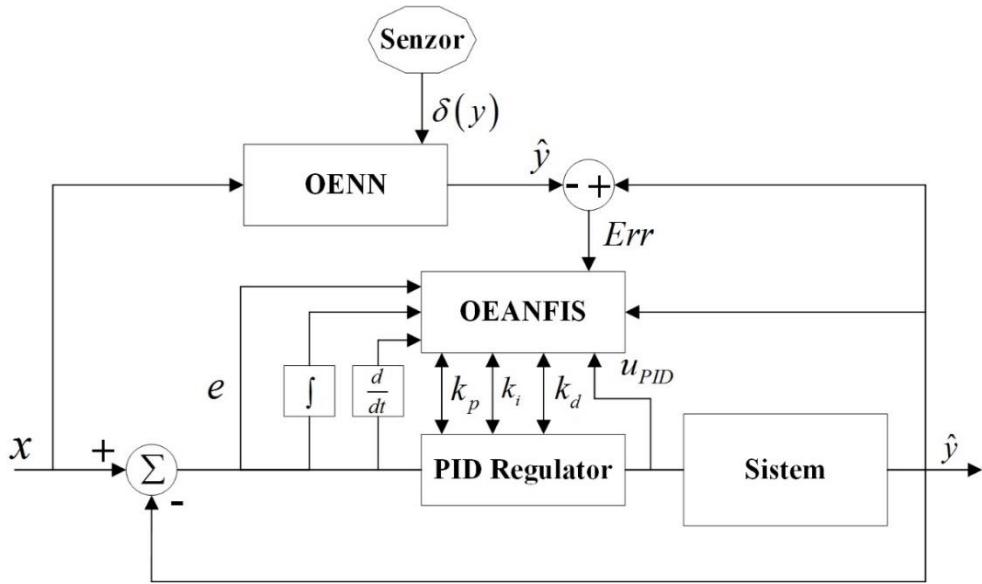
Predstavljena inteligentna struktura će u ovom potpoglavlju biti upotrebljena za *online* podešavanje parametara PID regulatora. Trening OENN-OEANFIS-a biće izvršen *offline* pre njegove implementacije unutar upravljačke logike sistema. OENN i OEANFIS podstrukture su trenirane odvojeno prema procedurama opisanim u prethodnom potpoglavlju. Način implementacije razvijenog intelligentnog modela unutar postojećeg upravljačkog sistema prikazan je na slici 8.2. Ulaz u OENN predstavlja referentni signal  $x$  koji će biti aproksimiran pomoću mreže. Stimulansi sredine su uvedeni u neuronsku mrežu u vidu signala devijacije/poremećaja  $\delta(y)$ . Signal  $\delta(y)$  predstavlja vektor koji sadrži izmerene vrednosti sa senzora sistema. Kao što je već napomenuto, ulazi OEANFIS-a su: dobijeni izlazni signali sistema  $\hat{y} = [\hat{y}_1, \hat{y}_2, \dots, \hat{y}_a]^T$ , upravljački signal iz PID regulatora ( $u_{PID}$ ), greška ( $e$ ), izvod greške ( $\frac{de}{dt}$ ) i integral greške ( $\int edt$ ). Od ovih grešaka je formiran jedinstveni vektor  $e_{est} = \left[ e, \frac{de}{dt}, \int edt \right]$  koji je uveden u OEANFIS kao adaptivna mera u okviru četvrtog sloja OEANFIS-a (Slika 8.1). Opšte zapisano, broj elemenata vektora  $e_{est}$  je  $p$ . Odabir vrednosti  $p$  određuje broj neurona u drugom, trećem i četvrtom sloju ( $\pi_p, N_p, P_p$ ). Vrednost  $p$  biće jednaka 3 za potrebe podešavanja PID regulatora. Izlaz OEANFIS-a ( $T_{PID}$ ) se može izračunati iz:

$$T_c = T_{PID} = \sum_p \bar{\mu}_p c_p Err_1 e + \sum_p \bar{\mu}_p c_p Err_2 \frac{de}{dt} + \sum_p \bar{\mu}_p c_p Err_3 \int edt, \quad (8.7)$$

gde je  $\bar{\mu}_p$  odgovarajući izlaz trećeg sloja,  $c_p$  je posledični parameter, a  $Err_1$ ,  $Err_2$  i  $Err_3$  su OENN signali. Konačno, izlaz celokupne OENN-OEANFIS strukture može se napisati u obliku:

$$T_{PID} = \Delta k_p e + \Delta k_d \frac{de}{dt} + \Delta k_i \int edt, \quad (8.8)$$

gde su  $\Delta k_p$ ,  $\Delta k_d$  i  $\Delta k_i$  prilagodljivi parametri konvencionalnog PID regulatora.



Slika 8.2 Implementacija OENN-OEANFIS strukture

Inicijalno podešavanje PID regulatora može se ostvariti korišćenjem neke od tradicionalnih tehniki. Detaljan prikaz podešavanja PID regulatora predstavljen je u (O'Dwyer, 2009). Inicijalni parametri regulatora su za potrebe ovog istraživanja određeni korišćenjem Ziegler–Nichols metode (O'Dwyer, 2009). *Online* određivanje PID parametara tokom upravljačkog procesa izvršavano je upotrebom sledećeg kriterijuma performansi:

$$J = \sum [e_i^2 + rk\Delta u_i^2], \quad (8.9)$$

gde je  $k$  pojačanje procesa,  $r$  je težinski faktor,  $\Delta u$  je promena upravljačkog signala i  $e_i$  je razlika između referentnog i realnog izlaznog signala koja se može izraziti kao:

$$e_i = y - \hat{y}. \quad (8.10)$$

U prethodnom potpoglavlju je definisan način određivanja parametara  $\Delta k_p$ ,  $\Delta k_d$  i  $\Delta k_i$ . Na osnovu toga se jednačine ažuriranja PID parametara mogu izraziti kao:

$$\begin{aligned} k_p &= k_p^0 + \Delta k_p, \\ k_i &= k_i^0 + \Delta k_i, \\ k_d &= k_d^0 + \Delta k_d, \end{aligned} \quad (8.11)$$

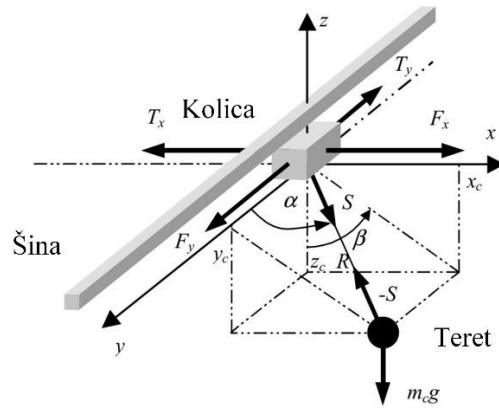
gde su  $k_p^0$ ,  $k_i^0$ , i  $k_d^0$  inicijalne vrednosti parametara. Parametri  $\Delta k_p$ ,  $\Delta k_d$  i  $\Delta k_i$  se preračunavaju u svakoj iteraciji s ciljem minimizacije signala greške.

### 8.3 Eksperiment na laboratorijskom modelu 3D krana

3D kran predstavlja kompleksan nelinearni elektromehanički sistem. Laboratorijski model korišćen u eksperimentalne svrhe (Slika 8.3) proizведен je od strane poljske kompanije Inteco. Baziran je na U/I RT-DAC3 akvizicionoj tabli opremljenoj A/D konvertorima. Akviziciona tabla emituje upravljačke signale koji se prenose od PC-ja do DC motora i konverte puksne signale enkodera u digitalnu formu (koja će biti procesirana na računaru). Računarska aplikacija koja omogućava kontrolu rada sistema naziva se „3D Crane Toolbox“ i njoj se može pristupiti direktno iz Matlab/Simulink softverskog okruženja.



Slika 8.3 Laboratorijski model 3D krana



Slika 8.4 Koordinate i sile sistema

Objekat upravljanja je teret izrađen od legure metala. Teret visi na pokretnom delu sistema i može se kretati u tri dimenzije. Povezan je sa pokretnim kolicima koja su instalirana na metalnoj šini. Šina i kolica se zajedno sa teretom mogu kretati po horizontalnoj osi u  $x$  pravcu. Kolica sa teretom takođe mogu da se kreću horizontalno duž šine u  $y$  pravcu. Samo teret može da se podiže i spušta duž  $z$  pravca. Instalirani enkoderi (sa rezolucijom 4096 ppr) mere 5 promenljivih stanja: koordinate kolica u  $x$  i  $y$  pravcima, poziciju tereta na  $z$  pravcu i dva devijaciona ugla tereta - koji su od glavnog interesa za ovo istraživanje. Uglovi devijacije u  $x$  i  $y$  pravcima su označeni kao ugao  $X(\alpha)$  i ugao  $Y(\beta)$ , respektivno. Glavni zadatak 3D krana je pomeranje tereta do željene pozicije na horizontalnoj i vertikalnoj osi, i njegova simultana stabilizacija tokom promene položaja, kao i smanjenje njegovih oscilacija. Teret se ponaša kao klatno tokom procesa stabilizacije. Period oscilacija ( $T$ ) može se izračunati kao:

$$T = 2\pi \sqrt{\frac{l}{g}}, \quad (8.12)$$

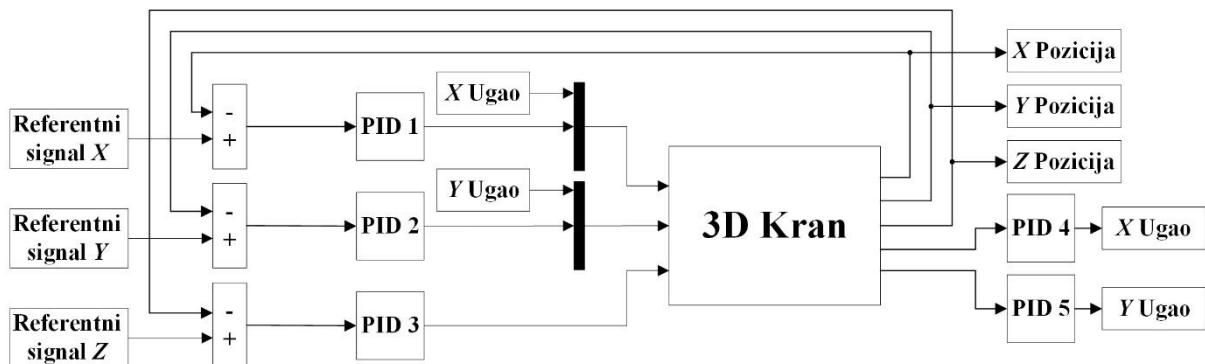
gde je  $l$  dužina klatna a  $g$  gravitaciona konstanta. Zadatak upravljanja sistemom se može definisati kao nalaženje kompromisa između preciznosti praćenja zadatog referentnog signala tereta i kvaliteta njegove stabilizacije tokom kretanja i pozicioniranja. Koordinate i sile sistema prikazane su na slici 8.4 (Antić, 2012b; Trajković, 2013; Precup, 2014). Izmerene promenljive stanja biće označene kao  $x_w$  (distanca na šini od centra rama),  $y_w$  (distanca kolica od centra šine),  $R$  (dužina puta koji teret može preći na vertikalnoj osi),  $\alpha$  i  $\beta$  uglovi. Dinamike krana mogu se opisati sledećim jednačinama:

$$\begin{aligned} m_c \ddot{x}_c &= -S_x, \\ m_c \ddot{y}_c &= -S_y, \\ m_c \ddot{z}_c &= -S_z - m_c g, \\ (m_w + m_s) \ddot{x}_w &= F_x - T_x + S_x, \\ m_w \ddot{y}_w &= F_y - T_y + S_y, \end{aligned} \quad (8.13)$$

gde su  $x_c$ ,  $y_c$  i  $z_c$  koordinate tereta,  $m_c$  je masa tereta,  $m_w$  i  $m_s$  su mase kolica i pokretne šine respektivno,  $F_x$  je pokretačka sila šine,  $F_y$  je pokretačka sila kolica, a  $T_x$  i  $T_y$  su sile trenja. Konačno,  $S_x$ ,  $S_y$  i  $S_z$  su komponente vektora  $S$  koji predstavlja silu reakcije na kolica duž vertikalne ose. Pozicija tereta se može definisati kao:

$$\begin{aligned} x_c &= x_w + R \cdot \sin \alpha \cdot \sin \beta, \\ y_c &= y_w + R \cdot \cos \alpha, \\ z_c &= -R \cdot \sin \alpha \cdot \cos \beta. \end{aligned} \quad (8.14)$$

Kompletan nelinearni matematički model sistema sa promenljivim dužinama klatna i tri upravljačke sile može se dobiti iz (Antić, 2012b; Trajković, 2013). Upravljačka logika koja će biti korišćena u eksperimentalne svrhe predstavljena je u vidu blok dijagrama na slici 8.5.



Slika 8.5 Upravljačka logika razmatranog sistema

## 8.4 Eksperimentalni rezultati

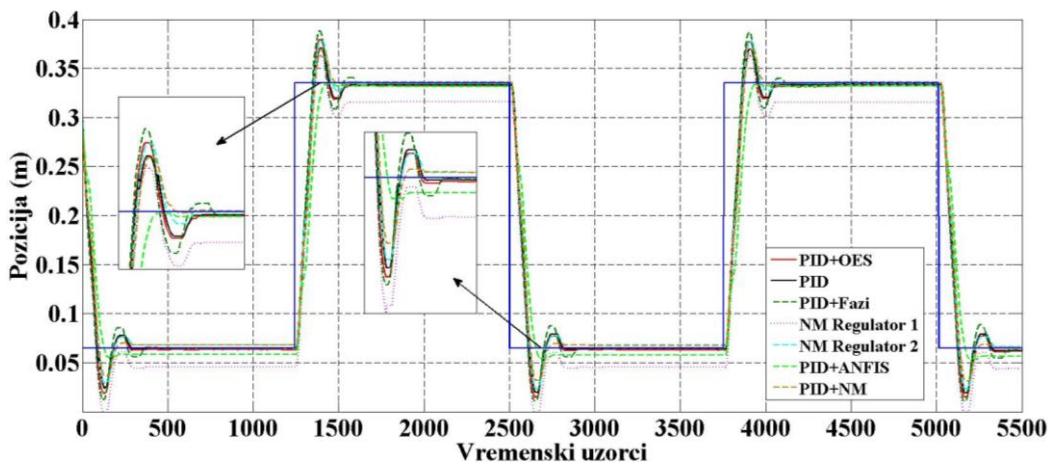
Eksperimenti su izvršeni upotrebom upravljačke logike sa slike 8.5. Referentni signali  $X$ ,  $Y$  i  $Z$  su dobijeni upotrebom signal generatora:  $X$  i  $Y$  imaju kvadratnu formu dok je  $Z$  izabran kao sinusni signal. Parametri PID regulatora podešeni su upotrebom Ziegler-Nichols-ove metode na sledeći način: PID 1 ( $k_p = 20, k_i = 10^{-7}, k_d = 10^{-6}$ ), PID 2 ( $k_p = 20, k_i = 4,7 \cdot 10^{-6}, k_d = 2 \cdot 10^{-6}$ ), PID 3 ( $k_p = 25, k_i = 3 \cdot 10^{-7}, k_d = 10^{-7}$ ). Regulatori PID 4 i PID 5 pojačavaju dobijene izlazne signale i poseduju samo proporcionalni uticaj:  $k_p = 10$ . Glavni cilj eksperimenata je optimizacija performansi sistema implementacijom hibridne inteligentne upravljačke logike unutar standardnog PID upravljanja. U istraživanju će parametri evaluacije performansi biti uglovi devijacije  $X$  i  $Y$ . Zadatak eksperimenata je minimizacija ovih devijacionih signala i dobijanje stabilizovanog kretanja tereta. Stabilnost tereta biće izražena njegovom manjom oscilatornošću duž  $X$  i  $Y$  osa tokom njegovog kretanja.

Projektovani adaptivni regulator je iskorišćen za *online* podešavanje i optimizaciju PID parametara tokom upravljačkog procesa. Implementacija OENN-OEANFIS strukture unutar upravljačke logike sa slike 8.5 izvršena je prema blok dijagramu prikazanom na slici 8.2. Tri identične strukture su iskorišćene za podešavanje regulatora PID1, PID 2 i PID 3. Adaptacija strukture sa slike 8.1 u formi koja je prikladna za implementaciju unutar upravljačke logike 3D krana biće obavljena kroz 13 koraka:

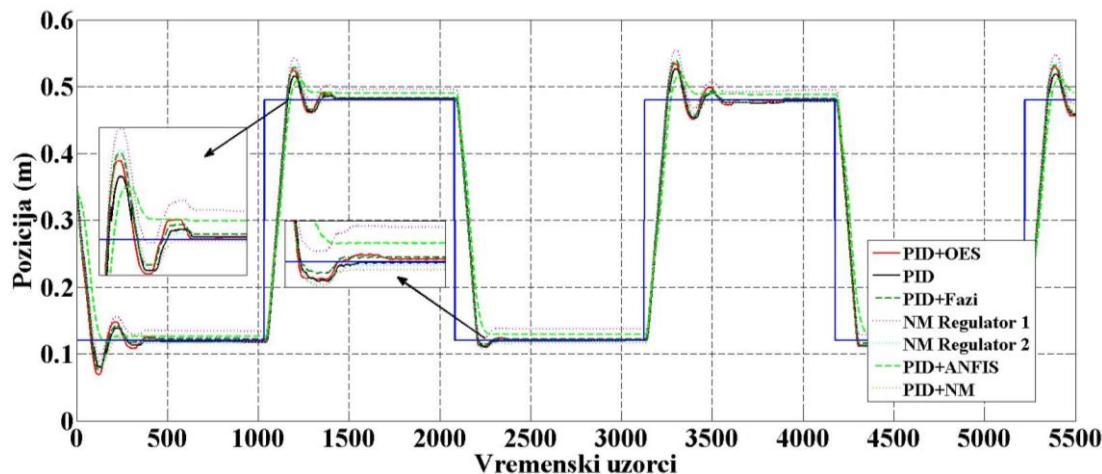
- (1) **Spoljašnji stimulansi.** Devijacioni uglovi  $X(\delta_1)$  i  $Y(\delta_2)$  su izabrani za spoljašnje stimulanse OENN-a.
- (2) **Broj žlezdi.** Početna provera izvršena je sa dve veštačke žlezde (po jedna za svaki stimulans) i broj žlezdi se povećavao za po jedan za svaku probu. Mreža je testirana empirijski i izabrane su strukture sa četiri žlezde (po dve za svaki stimulans).
- (3) **Endokrini parametri.** Stimulacioni parametar ( $R_g$ ) i koncentracija hormona ( $C_g$ ) određeni su prema (Timmis, 2009). Procedura selektovanja ovih parametara u (Timmis, 2009) se pokazala kao veoma efikasna u pogledu limitiranja brzih povećanja koncentracija hormona, pa će biti upotrebljena i za potrebe ovog istraživanja. Dalje, parameter osetljivosti ( $S_g$ ) jednak je 1 za svaku žlezdu. Oba stimulansa su podjednako važna za sistem pa neće biti favorizovan ni jedan od njih.
- (4) **OENN ulazi.** Ulaz u svaku mrežu je odgovarajuća referentna pozicija na  $X$ ,  $Y$  i  $Z$  osi (svaki ulaz mreže predstavlja po jedan od ova tri signala).

- (5) **OENN izlazi.** Ovo je jednoslojna mreža čiji je cilj aproksimacija referentnog pozicionog signala iz prethodnog koraka. Dobijeni izlazni signal ( $\hat{y}^{net}$ ) svake mreže je iskorišćen za formiranje veštačkog endokrinog stimulansa  $Err$  koji će biti uveden u OEANFIS.
- (6) **OENN: Broj ekspanzionih elemenata.** Svaka mreža sadrži 6 neurona u ovom sloju.
- (7) **OENN: Broj težina po žlezdi.** Kao što je rečeno, u ovom konkretnom slučaju su stimulansi sredine podjednako važni za sistem pa će se to reflektovati na korišćenje jednakog broja težina koje će biti pod uticajem svake žlezde. U prethodnom koraku je definisano 6 neurona u skrivenom sloju mreže. Pošto je broj žlezdi jednak 2, to znači da će svaki neuron pobuđivati po 3 težinska koeficijenta.
- (8) **OENN: trening skup.** Referentni signal pozicije, utvrđen na vremenskoj sekvenci od 100 sekundi, iskorišćen je za potrebe treninga. Rezultujući trening vektor sadržao je 10000 uzoraka. Podaci su podeljeni na sledeći način: 70% kao trening skup, 15% kao validacioni skup i preostalih 15% podataka iskorišćeno je za formiranje test skupa.
- (9) **OEANFIS ulazi.** Prva tri ulaza su izlazni signali sistema:  $X$ ,  $Y$  i  $Z$  signali pozicije tereta koji se mogu zapisati u obliku  $\hat{y} = [\hat{y}_1, \hat{y}_2, \hat{y}_3]^T$ . Četvrti ulaz je upravljački signal odgovarajućeg PID regulatora ( $u_{PID}$ ). Mreže 1, 2 i 3 dobijaju signale sa PID 1, PID 2 i PID 3 regulatora, respektivno. Poslednja tri ulaza su greška ( $e$ ), izvod greške ( $de/dt$ ), i integral greške ( $\int edt$ ).
- (10) **OEANFIS: broj elemenata u prvom sloju.** Svaki OEANFIS ulaz poseduje dve generalizovane funkcije pripadnosti tipa zvona, 14 ukupno.
- (11) **OEANFIS: broj elemenata u 2., 3. i 4. sloju.** Za potrebe podešavanja PID regulatora broj elemenata u svakom sloju je 3.
- (12) **OEANFIS: spoljašnji ulazi četvrtog sloja.** Svaki OEANFIS poseduje veštački stimulans sredine  $Err$  koji će biti korišćen za stimulaciju težina kao reakcije na intenzitet devijacionih signala. Elementi vektora  $e_{est}$  su takođe uvedeni u četvrti sloj, kao adaptivna mera signala greške.
- (13) **OEANFIS: trening skup.** Trening podaci za vremensku sekvencu od 100 sekundi su upotrebljeni za proces treninga. Ulazni vektor iz (8.8) i jedan izlazni vektor ( $T_{PID}$ ) su imali po 10000 elemenata. Prva polovina uzoraka iskorišćena je za formiranje baze trening podataka, a druga za formiranje podataka provere (validacije).

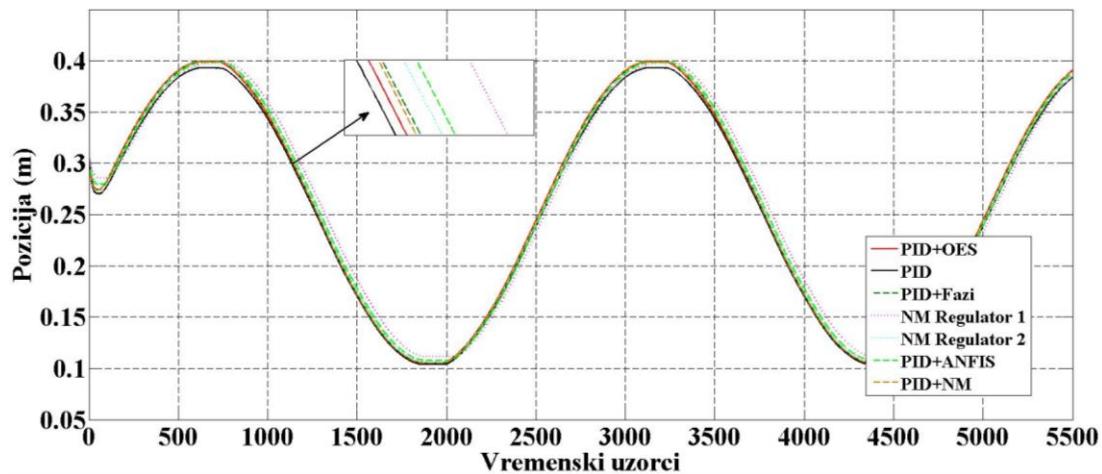
Eksperimentalna verifikacija predloženog OENN-OEANFIS-a dobijena je testiranjem adaptivne PID strukture na predstavljenom modelu 3D krana. Procedura testiranja uključila je snimanje performansi praćenja željenog signala pozicije tereta i merenje uglova devijacije. Parametri performansi praćenja koji su analizirani su: vreme uspona, vrednost pika, preskok, vreme smirenja i greška u ustaljenom stanju. Dva analizirana ugla devijacije obezbedila su informacije o nestabilnostima prilikom kretanja tereta. Primarni cilj istraživanja i upotrebe adaptivnog regulatora bio je minimizacija tih nestabilnosti koje se javljaju u vidu oscilacija tereta. Dobijeni OENN-OEANFIS eksperimentalni rezultati („PID+OES“ na slikama 8.6-8.10) su upoređeni sa tradicionalnim PID regulatorom („PID“), fazi samopodešavajućim PID regulatorom („PID+Fazi“) koji je razvijen u (Lou, 1996), neuronskom mrežom koja simulira rad PID regulatora („NM Regulator 1“), neuronskom mrežom koja simulira PID regulator i razvijena je u (Jin, 1997), hibridnim PID-ANFIS regulatorom („PID-ANFIS“) i hibridnim regulatorom koji se sastoji od tradicionalnog PID-a i neuronske mreže („PID+NM“). Hibridna PID-ANFIS struktura i samopodešavajući fazi PID regulator su realizovani tako da imaju slične strukture kao OEANFIS deo predstavljenog regulatora, osim implementiranih veštačkih stimulansa sredine i ortogonalnih funkcija. Takođe, NM Regulator 1, NM Regulator 2, i PID+NM struktura su sličnih karakteristika kao i OENN deo predloženog regulatora, osim implementiranih endokrinih faktora i upotrebe ortogonalnih funkcija. Sličnosti neuronskih mreža se ogledaju u jednakom broju ulaza, izlaza i broju neurona u skrivenom sloju za sve strukture. Neuronske mreže su projektovane korišćenjem standardnih aktivacionih funkcija. Konačno, procedure treninga za sve upotrebljene mreže su identične i prethodno opisane u potpoglavlju 8.2. Grafici praćenja željenog signala pozicije za 7 navedenih regulatora prikazani su na slikama 8.6-8.8 i označavaju pozicije terata na tri ose tokom vremenskog intervala od 55 sekundi. Analizirane su dve vremenske sekvence: prelazni procesi i ustaljeno stanje.



Slika 8.6. Pozicija tereta (X osa)



Slika 8.7 Pozicija tereta (Y osa)



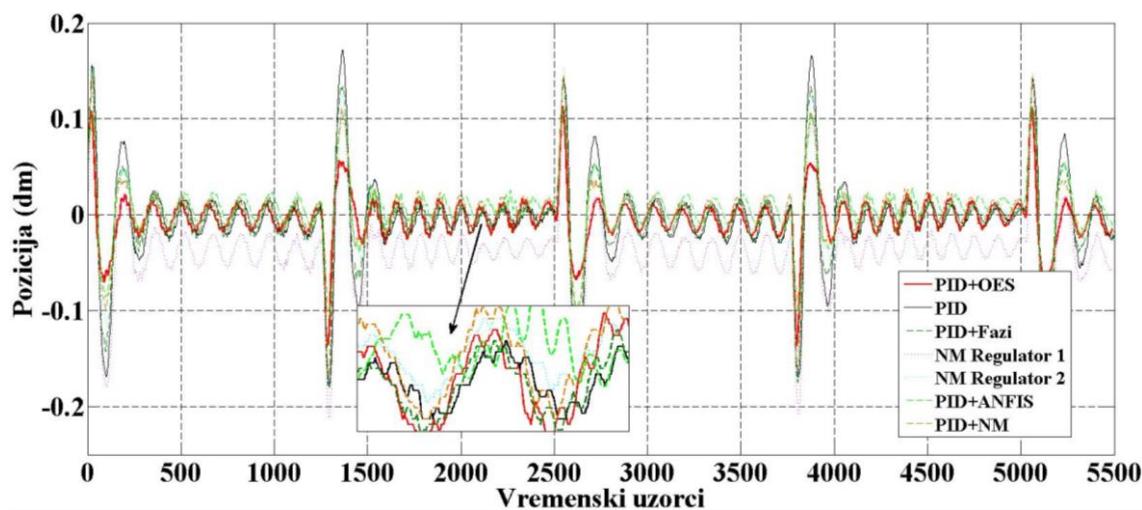
Slika 8.8 Pozicija tereta (Z osa)

Komparativna analiza ponašanja sistema tokom kretanja duž X ose predstavljena je u tabeli 8.1. Slične performanse su dobijene i za Y osu, pa zbog toga neće biti pravljena posebna analiza tih rezultata. Iz tabele 8.1 može se zaključiti da ne postoji jedinstveni regulator koji će obezbiti najbolje performanse po svim parametrima evaluacije. Najbrži regulator po pitanju vremena uspona i dostizanja pika je PID+Fazi regulator. Predložena PID+OES struktura je pokazala približne rezultate ovom regulatoru. PID+ANFIS regulator je jedini koji je obezbedio odziv bez preskoka i sa najbržim vremenom dostizanja ustaljenog stanja. Ipak, ovaj regulator poseduje i najveću grešku u ustaljenom stanju. NM Regulator 2 je pružio najmanju grešku u ustaljenom stanju (0,1%). U poređenju sa njim, struktura koja je realizovana u ovom istraživanju posedovala je grešku od 0,8%. U celini, predloženi PID+OES regulator je pokazao slične performanse u poređenju sa drugim testiranim inteligentnim strukturama.

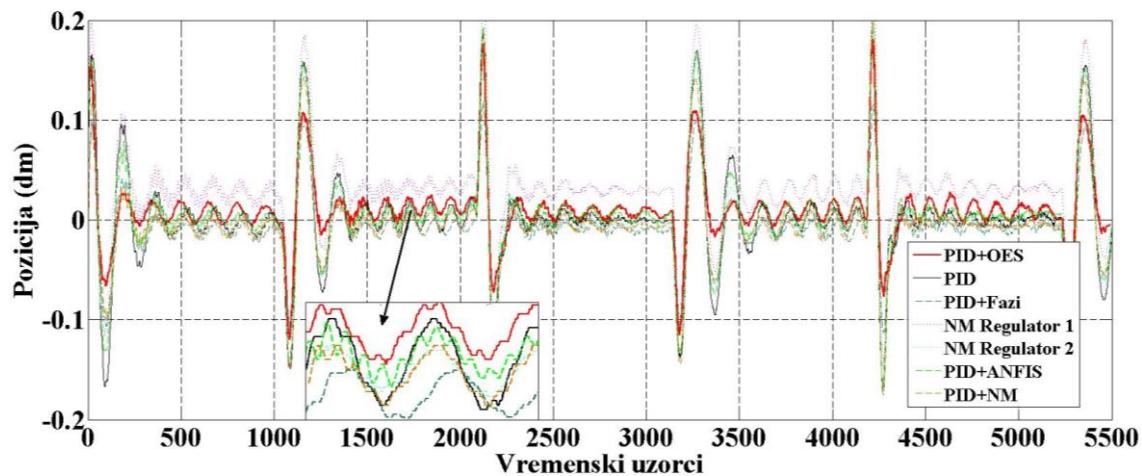
Tabela 8.1  
Poređenje eksperimentalnih rezultata (X osa)

Regulatori	Parametri sistema						
	Prelazni proces				Ustaljeno stanje		
	Vreme uspona (s)	Vreme pika (s)	Vrednost pika (m)	Preskok (%)	Vreme smirenja (s)	Greška u ustaljenom stanju (m)	Greška u ustaljenom stanju (%)
PID+OES	1,00	1,45	0,3791	13,16	3,14	0,0027	0,8
PID	1,03	1,50	0,3708	10,68	4,38	0,0020	0,6
PID+Fazi	<b>0,98</b>	<b>1,44</b>	0,3882	15,88	3,71	0,0024	0,7
NM Regulator 1	1,10	1,48	0,3645	8,81	3,27	0,0190	6,0
NM Regulator 2	1,04	1,52	0,3784	12,96	3,02	<b>0,0003</b>	<b>0,1</b>
PID+ANFIS	1,38	1,81	<b>0,334</b>	-	<b>2,43</b>	0,0032	0,97
PID+NM	1,1	1,52	0,3695	10,29	5,40	0,0007	0,21

Slike 8.9 i 8.10 predstavljaju poređenja izmerenih uglova devijacije sistema za 7 testiranih regulatora. Nulte pozicije na vertikalnim osama označavaju željene pozicije tereta kada na njega ne deluju poremećaji i nisu prisutni signali devijacije. Ukupna greška izmerenog signala poremećaja izračunata je sumiranjem svih apsolutnih vrednosti devijacije za sve vremenske uzorke. Poređenja preciznih numeričkih rezultata prikazana su u tabeli 8.2. Eksperimentalni rezultati su pokazali da *online* podešavanje PID regulatora upotrebom OENN-OEANFIS strukture može da obezbedi stabilizaciju kretanja upravljačkog objekta i minimizaciju njegovih oscilacija.



Slika 8.9 Devijacioni signali tereta (na X osama) pre i nakon implementacije inteligentnih struktura



Slika 8.10 Devijacioni signali tereta (na  $Y$  osama) pre i nakon implementacije inteligentnih struktura

Tabela 8.2  
Poređenje uglova devijacije

Regulator	PID +OES	PID	PID +Fazi	NM Regulator 1	NM Regulator 2	PID +ANFIS	PID+NM
Ugao devijacije $X$ – greška	<b>142,42</b>	233,0	202,14	255,1716	237,6412	184,367	216,7804
Ugao devijacije $Y$ – greška	<b>163,73</b>	246,3	229,87	237,64	204,37	191,67	229,51

Glavni doprinos strukture je smanjenje signala devijacije koje sistem pokazuje tokom procesa upravljanja – u poređenju sa tradicionalnim PID regulatorom, testiranim regulatorima baziranim na neuronskim mrežama i tri adaptivna PID regulatora. OENN-OEANFIS struktura je, u poređenju sa drugim testiranim regulatorima, minimizovala signale devijacije između 29% i 79% za devijacioni ugao  $X$ , i u opsegu od 17% do 50% za devijacioni ugao  $Y$ . Nedostatak predloženog adaptivnog regulatora predstavlja kompleksnost samog modela i ne preporučuje se korišćenje ove strukture kada je zadatok upravljanje linearnim ili jednostavnim nelinearnim sistemom koji nije pod uticajem izraženih signala poremećaja.

## Zaključak

Predmet proučavanja ove doktorske disertacije je upravljanje dinamičkim sistemima upotrebom novih tipova ortogonalnih endokrinih neuronskih mreža, u cilju poboljšanja performansi sistema. Ciljevi naučnih istraživanja bili su razvoj novih adaptivnih osobina neuronskih mreža sa akcentom na razvoj endokrinih adaptivnih neuronskih mreža i endokrinih adaptivnih neuro-fazi hibridnih sistema. Shodno tome, u prvom i drugom poglavlju data je generalizacija standardnih neuronskih mreža, kao i dosadašnji razvoj endokrinih i ortogonalnih mreža na kojima je i bazirana disertacija. U prvom poglavlju prikazan je istorijski razvoj, napravljeno je poređenje sa biološkim modelom mreže i detaljno su predstavljeni veštački model neurona i struktura standardne mreže. Na kraju poglavlja prikazani su osnovni tipovi učenja i načini za njihovu matematičku implementaciju. U drugom poglavlju predstavljene su različite primene veštačkih neuronskih mreža u upravljačkim aplikacijama, kao i trenutno stanje razvoja ortogonalnih i endokrinih mreža, kao baze za nadogradnju u ostalim poglavljima disertacije.

U trećem poglavlju je upotrebljena standardna neuronska mreža sa *backpropagation* tipom učenja za poboljšanje performansi servo sistema. Najpre su projektovani Luenbergerov observer stanja i regulator promenljive strukture, nakon čega su izvršeni eksperimenti sa modifikovanom upravljačkom logikom sistema. Zatim je projektovana i implementirana standardna neuronska mreža u okviru upravljačke logike promenljive strukture ovog sistema. Na kraju je empirijski pokazano da upravljanje zasnovano na integraciji neuronske mreže u okviru konvencionalne upravljačke logike, može obezbediti poboljšane performanse sistema u vidu boljeg praćenja željenog signala u stacionarnom stanju i manje greške tokom prelaznih procesa.

Četvrto poglavlje opisuje metodu za selekciju i optimizaciju velikih trening skupova podataka, kao vid preprocesiranja podataka za efikasniji rad neuronske mreže. Za potrebe testiranja metode upotrebljeni su ekonomski sistemi za koje važe osobine nelinearnosti, promenljivosti i neotpornosti na poremećaje. Kao takvi, ovi sistemi predstavljaju pravi izazov za procesiranje i predikciju, kako pomoću tradicionalnih metoda, tako i neuronskih mreža. Originalna baza podataka u prvoj fazi preprocesiranja bila je podvrgнутa PCA analizi. Nakon ove analize utvrđene su međusobne zavisnosti dobijenih dominantnih komponenti i formirani optimizovani ulazni i izlazni trening vektori neuronske mreže. U završnoj fazi projektovana je

standardna neuronska mreža i trenirana upotrebom formiranih vektora, da bi na kraju bili prikazani dobijeni simulacioni rezultati.

Prvi deo petog poglavlja opisuje ortogonalne funkcije, daje njihove karakteristike i uvodi matematički aparat kojim su definisane. Dalje, predstavljeni su generalizovani kvazi ortogonalni polinomi Ležandrovog tipa, Čebiševljevi polinomi prve vrste i ortogonalne trigonometrijske funkcije. Akcenat je stavljen na ova tri tipa polinoma iz razloga što su u nastavku bile realizovane neuronske mreže koje su ih sadržale u svom sastavu. Nakon toga, izvršena je implementacija ortogonalnih funkcija u vidu aktivacionih funkcija standardne neuronske mreže. Za eksperimentalnu proveru novih ortogonalnih aktivacionih funkcija upotrebljen je laboratorijski model magnetnog levitatora. Upravljačka logika bazirana na LQ regulatoru nadograđena je implementacijom projektovane neuronske mreže. Najpre je pokazano da standardna upravljačka logika, kao i upravljanje sa dodatkom implementirane neuronske mreže (bazirane na logaritamskim i hiperboličnim aktivacionim funkcijama) ne mogu pružiti zadovoljavajuće performanse za pojedine zadatke dvopozicione levitacije metalne lopte. U svrhu poboljšanja levitacije, implementirana je mreža bazirana na ortogonalnim funkcijama, izvršen je niz eksperimentalnih provera i utvrđeno da realizovane mreže mogu obezbediti bolje performanse po pitanju većeg dvopozicionog pomeraja levitacionog objekta.

Na početku šestog poglavlja predstavljene su endokrine neuronske mreže, način njihove realizacije i implementacije u okviru standardnih mreža. Dalje, realizovana je ortogonalna neuronska mreža bazirana na postsinaptičkim potencijalima koji su zasnovani na biološkim procesima ekscitacije i inhibicije. Imitacijom bioloških procesa izvršen je uticaj na dodatno pobuđivanje pojedinih težinskih koeficijenata neuronske mreže. Na taj način ostvaren je efekat aktivacionog izoštravanja protoka informacija kroz mrežu, čime se umanjila mogućnost pojave katastrofalnog zaboravljanja mreže. Realizovana mreža testirana je za predikciju vremenskih sekvenci podataka – predikciju dnevnih kurseva novčanih valuta. Dobijeni rezultati su upoređeni sa rezultatima dobijenim iz neuronskih mreža koje su se tradicionalno pokazale kao dobar alat za predikciju informacija. Na osnovu dobijenih rezultata zaključilo se da su prediktivne sposobnosti nove mreže u rangu sa sposobnostima drugih testiranih mreža. Glavna prednost dobijene strukture je primetno smanjenje proračunskog vremena, što se opravdava poludistribuiranim prenosom podataka kroz mrežu.

U sedmom poglavlju realizovan je adaptivni endokrini neuro-fazi hibridni sistem (OEANFIS). Dat je prikaz topologije ovakvog sistema, način obrade informacija od ulaza do izlaza i metoda implementacije endokrinog faktora u okviru standardne mreže. Realizovani sistem je testiran modeliranjem laboratorijskog modela servo sistema. Za potrebe modeliranja

sistema upotrebljeni su trening skupovi koji se sastoje od napona (ulaznih podataka) i ugaonih brzina (izlaznih podataka), zabeleženih za 180 sekundi rada realnog sistema. Realizovana mreža zahtevala je manje proračunsko vreme u odnosu na ono potrebno standardnom ANFIS-u. Greške treniranja i testiranja nove mreže su značajno manje od grešaka koje tokom rada pravi standardna ANFIS struktura.

U poslednjem, osmom poglavlju ove doktorske disertacije, projektovana je hibridna OENN-OEANFIS struktura. Cilj pri formiraju složene strukture bio je simbioza pozitivnih karakteristika i osobina endokrinih struktura, dobijenih u poglavljima 5, 6 i 7. Nakon predstavljanja konfiguracije nove strukture, pojedinačno su predstavljene dve upotrebljene podstrukture: OENN i OEANFIS. Nakon toga su dati koraci za postavku i inicijalizaciju celokupne hibridne strukture. Verifikacija rada strukture izvršena je njenom upotreboom pri podešavanju parametara PID regulatora. Podesivi PID regulatori upotrebljeni su za kontrolu rada laboratorijskog modela 3D krana. Akcenat istraživanja bio je na uvođenju signala devijacije krana u vidu endokrinog faktora hibridnog sistema. Cilj unapređenja performansi upravljačke strukture bila je minimizacija dva signala devijacije (poremećaja prilikom kretanja duž  $X$  i  $Y$  osa) i stabilizovanje kretanja tereta. Performanse sistema upoređene su sa rezultatima koje daju mreže sa sličnim strukturama i to po pitanju ponašanja sistema u prelaznim procesima i ustaljenim stanjima. Pokazalo se da novi OENN-OEANFIS sistem pruža slične rezultate onima koje daju druge mreže u smislu praćenja želenog signala. Bolje performanse su ostvarene po ceni veće kompleksnosti upravljačke logike.

Navedena razmatranja u ovoj doktorskoj disertaciji pokazala su da je moguće poboljšati performanse standardnih neuronskih mreža uvođenjem veštačkog endokrinog faktora u okviru postojećih struktura. Na taj način se vrši obrada uticaja spoljašnje sredine na efikasan način, čime se postiže dodatna osjetljivost i adaptivnost mreže na različite interne i eksterne faktore. Dokazano je da su takvi endokrini sistemi upotrebljivi pri upravljanju različitim dinamičkim sistemima, kao i u predikciji nelinearnih i visoko promenljivih vremenskih sekvenci podataka. Druga prednost razvijenih modela je upotreba različitih tipova ortogonalnih funkcija pri procesiranju podataka, čime se postiže veća aproksimaciona moć sistema. Dalja istraživanja u ovoj oblasti mogu se sprovesti po pitanju unapređenja efikasnosti uvedenog endokrinog faktora na stepen adaptivnosti neuronske mreže. Takođe, prostor za dalji razvoj postoji u implementaciji endokrinih faktora u okviru različitih tipova standardnih neuronskih mreža na koje, do sada, nije bilo primenjeno delovanje veštačkih žlezdi.

# **Doprinosi doktorske disertacije**

Doktorska disertacija sadrži sledeće doprinose:

- realizovanje nove univerzalne metode optimizacije trening podataka kao neophodnog koraka za uspešno modeliranje neuronskim mrežama;
- projektovanje standardne neuronske mreže sa implementiranim ortogonalnim aktivacionim funkcijama;
- projektovanje ortogonalne endokrine neuronske mreže koja je zasnovana na adaptivnom parametru osetljivosti;
- projektovanje ortogonalnog endokrinog ANFIS-a;
- realizovanje inteligentnog hibridnog sistema koji je zasnovan na kombinaciji ortogonalnog endokrinog ANFIS-a i ortogonalne endokrine neuronske mreže;
- implementaciju neuronskih mreža u upravljačke logike dinamičkih sistema;
- verifikovanje svih projektovanih modela inteligentnog upravljanja računarskim simulacijama i nizom laboratorijskih eksperimenata;
- upoređivanje rezultata ostvarenih korišćenjem projektovanih modela sa rezultatima koji su dobijeni upotrebom postojećih neuronskih mreža;
- sveobuhvatna analiza dobijenih rezultata.

# Literatura

## A

Abdi, H., L. Williams, “Principal Components Analysis”, *Wiley Interdisciplinary Reviews: Computational Statistics*, vol. 2, no. 4, pp. 433-459, 2010.

Abramovic, M., I. Stegun, “Handbook of Mathematical Functions: with Formulas, Graphs, and Mathematical Tables”, *National Bureau of Standards Applied Mathematics Series*, Washington, 1972.

Atri, A., M. Ilyas, “Speed Control of DC Motor using Neural Network Configuration”, *International Journal of Advanced Research Computer Science and Software Engineering*, vol. 2, no. 5, pp. 209-212, 2012.

Alfaro, M., L. Moral, “Quasi-orthogonality on the Unit Circle and Semi-classical Forms”, *Portugaliae Mathematica*, vol. 51, no. /, pp. 47-62, 1991.

Ans, B., S. Rousset, “Neural Networks With a Self-refreshing Memory: Knowledge Transfer in Sequential Learning Tasks Without Catastrophic Forgetting”, *Connection Science*, vol. 12, no. 1, pp. 1-19, 2000.

Antić, D., M. Milovanović, S. S. Nikolić, M. Milojković, S. Perić, “Simulation Model of Magnetic Levitation Based on NARX Neural Networks”, *International Journal of Intelligent Systems and Applications*, vol. 5, no. 5, pp. 25-32, 2013.

Antić, D., Z. Jovanović, V. Nikolić, M. Milojković, S. Nikolić, N. Danković, “Modeling of Cascade-connected Systems Using Quasi-orthogonal Functions”, *Electronics and Electrical Engineering*, vol. 18, no. 10, pp. 3-8, 2012a.

Antić, D., B. Danković, S. Nikolić, M. Milojković, Z. Jovanović, “Approximation Based on Orthogonal and Almost Orthogonal functions”, *Journal of the Franklin Institute*, vol. 349, no. 1, pp. 323-336, 2012b.

Antić, D., M. Milojković, Z. Jovanović, S. Nikolić, “Optimal Design of the Fuzzy Sliding Mode Control for a DC Servo Drive”, *Journal of Mechanical Engineering*, vol. 56, no. 7-8, pp. 455-463, 2010.

## B

Barie, W., J. Chiasson, “Linear and Nonlinear State-space Controllers for Magnetic Levitation”, *International Journal of Systems Science*, vol. 27, no. 11, pp. 1153-1163, 1996.

Billings, S., H. Jamaluddin, S. Chen, "A Comparison of the Backpropagation and Recursive Prediction Error Algorithms for Training Neural Networks", *Mechanical Systems and Signal Processing*, vol. 5, no. 3, pp. 233-255, 1991.

Bojan-Dragos, C.-A., A.-I. Stinean, R.-E. Precup, S. Preitl, E. M. Petriu, "Model Predictive Control Solution for Magnetic Levitation Systems", in *Proceedings of 20<sup>th</sup> International Conference on Methods and Models in Automation and Robotics*, Miedzyzdroje, Poland, pp. 139-144, 2015.

Božić, J., D. Babić, "EUR/RSD Exchange Rate Forecasting Using Hybrid Wavelet-neural Model: A Case Study", *Computer Science and Information Systems*, vol. 12, no. 2, pp. 487-508, 2015.

Bretas, A., A. Phadke, "Artificial Neural Networks in Power System Restoration", *IEEE Transactions on Power Delivery*, vol. 18, no. 4, pp. 1181-1186, 2003.

Brezinski, C., K. A. Driver, M. Redivo-Zaglia, "Quasi-orthogonality with Applications to Some Families of Classical Orthogonal Polynomials", *Applied Numerical Mathematics*, vol. 48, no. 2, pp. 157-168, 2004.

Burrascano, P., "A Norm Selection Criterion for the Generalized Delta Rule". *IEEE Transactions on Neural Networks*, vol. 2, no. 1, pp. 125-130, 1991.

## C

Chen, C., C. Tseng, "Performance Comparison Between the Training Method and the Numerical Method of the Orthogonal Neural Network in Function Approximation", *International Journal of Intelligent Systems*, vol. 19, no. 12, pp. 1257-1275, 2004.

Chen, Y., L. Peng, A. Abraham, "Exchange Rate Forecasting Using Flexible Neural Trees", in: *Advances in Neural Networks, Lecture Notes in Computer Science*, Springer, Berlin Heidelberg, vol. 3973, no. /, pp. 518-523, 2006.

Chen, A., Y. Hsu, K. Hu, "A Hybrid Forecasting Model for Foreign Exchange Rate Based on a Multi-neural Network", in *Proceedings of 4<sup>th</sup> International Conference on Natural Computation, ICNC 2008*, vol. 5, no. /, pp. 293-298, 2008.

Chen, C., D. Naidu, "Hybrid Control Strategies for a Five-finger Robotic Hand", *Biomedical Signal Processing and Control*, vol. 8, no. 4, pp. 382-390, 2013.

Chen, D., J. Wang, F. Zou, W. Yuan, W. Hou, "Time Series Prediction with Improved Neuro-endocrine Model", *Neural Computing and Applications*, vol. 24, no. 6, pp. 1465-1475, 2014.

Chiang, H.-K., C.-C. Fang, W.-B. Lin, G.-W. Chen, “Second-order Sliding Mode Control for a Magnetic Levitation System”, in *Proceedings of 8<sup>th</sup> Asian Control Conference*, Kaohsiung, Taiwan, pp. 602-607, 2011.

Chihara, T. S., “On Quasi-orthogonal Polynomials”, *Proceedings of the American Mathematical Society*, vol. 8, no. /, pp. 765-767, 1957.

Chilikin, M., “Electric Drive”, *MIR Publishers*, Moscow, 1976.

## D

Danković, B., S. Nikolić, M. Milojković, Z. Jovanović, “A Class of Almost Orthogonal Filters”, *Journal of Circuits, Systems, and Computer*, vol. 18, no. 5, pp. 923-931, 2009a.

Danković, B., P. Rajković, S. Marinković, “On a Class of Almost Orthogonal Polynomials”, in *Lecture Notes in Computer Science 5434*, Eds. Margenov, S., L. G. Vulkov, J. Wasniewski, Springer-Verlag, Berlin, pp. 241-248, 2009b.

Deckers, K., A. Bultheel, “Orthogonal Rational Functions with Complex Poles: The Favard Theorem”, *Journal of Mathematical Analysis and Applications*, vol. 356, no. 2, pp. 764-768, 2009.

Demuth, H., M. Beale, M. Hagan, “Neural Network Toolbox™ 6 - User’s Guide”, *The MathWorks*, 2013.

Deun, J. V., A. Bultheel, “Orthogonal Rational Functions and Quadrature on an Interval”, *Journal of Computational and Applied Mathematics*, vol. 153, no. /, pp. 487-495, 2003.

Dobrescu, E., I. Nastac, E. Pelinescu, “An Adaptive Retraining Method for the Exchange Rate Forecasting”, *Romanian Journal of Economic Forecasting*, vol. 7, no. 1, pp. 5-23, 2006.

Dragoş, C.-A., R.-E. Precup, E. M. Petriu, M. L. Tomescu, St. Preitl, R.-C. David, M.-B. Rădac, “2-DOF PI-fuzzy Controllers for a Magnetic Levitation System”, in *Proc. of 8<sup>th</sup> International Conference on Informatics in Control, Automation and Robotics*, Noordwijkerhout, Netherlands, vol. 1, no. /, pp. 111-116, 2011.

Dzung, P., L. Phuong, “Control System DC Motor with Speed Estimator by Neural Networks”, *Power Electronics and Drives Systems*, vol. 2, no. /, pp. 1030-1035, 2005.

## E

Erdogan, O., A. Goksu, “Forecasting Euro and Turkish Lira Exchange Rates with Artificial Neural Networks (ANN)”, *International Journal of Academic Research in Accounting, Finance and Management Sciences*, vol. 4, no. 4, pp. 307-316, 2014.

**F**

Fang, Y., T.-W.-S. Chow, "Orthogonal Wavelet Neural Networks Applying to Identification of Wiener Model", *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, vol. 47, no. 4, pp. 591-593, 2000.

Farhani, F., A. Zaafouri, A. Chaari, "Gain-scheduled Adaptive Observer for Induction Motors: An LMI Approach", *Acta Polytechnica Hungarica*, vol. 11, no. 1, pp. 49-61, 2014.

Farooq, U., J. Gu, M. E. El-Hawary, G. Abbas, M. U. Asad, "An Interval Type-2 Fuzzy Regulator for Magnetic Levitation System", in *Proc. of IEEE 28th Canadian Conference on Electrical and Computer Engineering*, Halifax, Canada, pp. 424-431, 2015.

French, R., "Using Semi-distributed Representations to Overcome Catastrophic Forgetting in Connectionist Networks", in: *Proceedings of the 13th Annual Cognitive Science Society Conference*, vol. 1, no. /, pp. 173-178, 1991.

**G**

Gabor, D., "Theory of Communication. Part 1: The Analysis of Information", *Journal of the Institution of Electrical Engineers-Part III: Radio and Communication Engineering*, vol. 93, no. 26, pp. 429-441, 1946.

Gardner, M., S. Dorling, "Artificial Neural Networks (The Multilayer Perceptron) - A Review of Applications in the Atmospheric Sciences", *Atmospheric Environment*, vol. 32, no. 14-15, pp. 2627-2636, 1998.

Gomes, G. S., T. B. Ludermir, L. M. Lima, "Comparison of New Activation Functions in Neural Network for Forecasting Financial Time Series", *Neural Computing and Applications*, vol. 20, no. 3, pp. 417-439, 2010.

**H**

Haley, P., D. Soloway, B. Gold, "Real-time Adaptive Control Using Neural Generalized Predictive Control", in *Proc. of the American Control Conference*, San Diego, USA, vol. 6, no. /, pp. 4278-4282, 1999.

Haque, T., M. Kashtiban, "Application of Neural Networks in Power Systems", *World Academy of Science, Engineering and Technology*, vol. 1, no. 6, pp. 917-927, 2005.

Hertz, J., A. Krogh, R. Palmer, "Introduction to the Theory of Neural Computation", *MA: Addison-Wesley*, Reading, 1991.

Ho, S., L. Shu, S. Ho, "Optimizing Fuzzy Neural Networks for Tuning PID Controllers Using an Orthogonal Simulated Annealing Algorithm OSA", *IEEE Transactions on Fuzzy Systems*, vol. 14, no. 3, pp. 421-434, 2006.

Hongwei, W., G. Hong, "Chaotic Synchronization in the Presence of Disturbances Based on an Orthogonal Function Neural Network", *Asian Journal of Control*, vol. 10, no. 4, pp. 470-477, 2008.

## I

Imandoust, S., S. Fahimifard, "Application of NNRAX to Agricultural Economic Variables Forecasting", *Journal of Applied Sciences*, vol. 10, no. 13, pp. 1263-1270, 2010.

Internet dokument, Inteco, "Modular Servo System - User's Manual", dostupan na web adresi: [http://sharif.edu/~namvar/index\\_files/servo\\_um.pdf](http://sharif.edu/~namvar/index_files/servo_um.pdf), 2008, (1).

Internet dokument, dostupan na web adresi: www.dc-motorshop.com/Motoren/DC+Motoren/artikel/1.13.044.236+-+24+V+DC+Motor.html, 2014, (2).

Internet dokument, dostupan na web adresi: <http://principalglobalindicators.org>, 2013, (3).

Internet dokument, dostupan na web adresi: <http://elibrary-data.imf.org>, 2013, (4).

Internet dokument, dostupan na web adresi: <http://epp.eurostat.ec.europa.eu>, 2013, (5).

Internet dokument, dostupan na web adresi: <http://www.inteco.com.pl/products/magnetic-levitation-systems/>, 2015, (6).

Internet dokument, The MathWorks Inc., "Fuzzy Logic Toolbox™ User's Guide", dostupan na web adresi: [http://www.mathworks.com/help/pdf\\_doc/fuzzy/fuzzy.pdf](http://www.mathworks.com/help/pdf_doc/fuzzy/fuzzy.pdf), 2016, (7).

Internet dokument, dostupan na web adresi: <http://fx.sauder.ubc.ca/>, 2014, (8).

Ishaque, K., Y. Saleem, S. S. Abdullah, M. Amjad, M. Rashid, S. Kazi, "Modeling and Control of Magnetic Levitation System via Fuzzy Logic Controller", in *Proc. of 2011 4<sup>th</sup> International Conference on Modeling, Simulation and Applied Optimization*, Kuala Lumpur, Malaysia, pp. 1-6, 2011.

Ishiguro, A., T. Furuhashi, S. Okuma, "A Neural Network Compensator for Uncertainties of Robotics Manipulators", *IEEE Transactions on Industrial Electronics*, vol. 39, no. 6, pp. 565-570, 1992.

## J

Jang, J.-S. R., "ANFIS: Adaptive Network-based Fuzzy Inference Systems", *IEEE Transaction on Systems, Man and Cybernetics*, vol. 23, no. 3, pp. 665-685, 1993.

Jang, J.-S. R., C.-T. Sun, "Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence", *Prentice Hall*, New Jersey, 1997.

Jeong, D. H., C. Ziemkiewicz, W. Ribarsky, R. Chang, "Understanding Principal Component Analysis Using a Visual Analytics Tool", *UNC Charlotte*, in Charlotte Visualization Center, 2009.

Jeon, J., M. Caraiani, K. Lee, D. Hwang, J. Lee, Y. Kim, T. Nam, S. Kim, "High-precision Control of Magnetic Levitation System", in *Proc. of the 31<sup>st</sup> Annual Conference of Industrial Electronics Society*, Gyeonggi-Do, Korea, pp. 1-6, 2005.

Jian, B., Y. Yi, Z. Bin, "Research on Real-time Image Sharpening Methods Based on Optimized Neural Network", in *Proceedings of the 5<sup>th</sup> International Conference on Natural Computation*, vol. 2, no. /, pp. 424-428, 2009.

Jin, W., G. Wenzhong, G. Shusheng, W. Fuli, "PID-like Controller Using a Modified Neural Network", *International Journal of Systems Science*, vol. 28, no. 8, pp. 809-815, 1997.

Jung, J.-W., V.-Q. Leu, T.-D. Do, E.-K. Kim, H.-H. Choi, "Adaptive PID Speed Control Design for Permanent Magnet Synchronous Motor Drives", *IEEE Transactions on Power Electronics*, vol. 30, no. 2, pp. 900-908, 2014.

## **K**

Kaastra, I., M. Boyd, "Designing a Neural Network for Forecasting Financial and Economic Time Series", *Neurocomputing*, vol. 10, no. 3, pp. 215-236, 1996.

Khalil, H., "Nonlinear Systems", *Prentice Hall*, New Jersey, 2002.

Kiss, P., V. Prodanov, J. Glas, "Complex Low-pass Filters", *International Journal of Analog Integrated Circuits and Signal Processing*, vol. 35, no. 1, pp. 9-23, 2003.

Kumar, K., "Backpropagation Algorithm for a Generalized Neural Network Structure", in *Proceedings of the IEEE S Southeastcon*, vol. 2, no. /, pp. 646-649, 1992.

Kusagur, A., S. F. Kodad, B. V. Sankar, "Speed Control of Separately Excited DC Motor using Neuro Fuzzy Technique", *International Journal of Computer Applications*, vol. 6, no. 12, pp. 29-44, 2010.

## **L**

Lairi, M., G. Bloch, "A Neural Network with Minimal Structure for Maglev System Modeling and Control", in *Proc. of the 1999 IEEE International Intelligent Control/Intelligent Systems and Semiotics*, Cambridge, USA, pp. 40-45, 1999.

Lang, G. R., P. O. Brackett, "Complex Analogue Filters", *Proceedings of the European Conference on Circuit Theory and Design*, Hague, Netherlands, pp. 412-419, 1981.

Lavanya, M., P. Kartheek, B. Nagaparvathi, K. Vineesh, "Two Tank Water Level Control Level System Using Pi, Pd and Pid Controllers", *International Journal of Applied Engineering Research*, vol. 10, no. 1, pp. 1195-1206, 2015.

Lee, C., P. Chung, J. Tsai, C. Chang, "Robust Radial Basis Function Neural Networks", *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 29, no. 6, pp. 674-685, 1999.

- Li, A., J. Wu, "Modeling and Prediction with Wavelet Neural Network in the On-linear Time Series", *International Review on Computers and Software*, vol. 7, no. 7, pp. 3617-3621, 2012.
- Lin, C., "Control Engineering Practice Design of a Composite Recurrent Laguerre Orthogonal Polynomial Neural Network Control System With Ameliorated Particle Swarm Optimization for a Continuously Variable Transmission System", *Control Engineering Practice*, vol. 49, no. /, pp. 42-59, 2013.
- Long, Y., "Study on Non-linearity Mode Building Method Based on Lagurre Orthogonal Polynomial Basis Functions Neural Network for Eddy Current Sensor", *International Journal of Advancements in Computing Technology*, vol. 4, no. 21, pp. 574-581, 2012.
- Lou, K.-N., C.-Y. Kuo, L.-T. Sheu, "A Novel Method for Fuzzy Self-tuning PID Controllers", *In Fuzzy Systems Symposium Soft Computing in Intelligent Systems and Information Processing*, pp. 194-199, 1996.
- Luat, T. H., J.-H. Cho, Y.-T. Kim, "Fuzzy-tuning PID Controller for Nonlinear Electromagnetic Levitation System", in: *Soft Computing in Intelligent Control*, Kim, S., J.-W. Jung, N. Kubota, Eds., *Advances in Intelligent Systems and Computing*, Springer International Publishing, vol. 272, no. /, pp. 17-28, 2014.
- Luenberger, G., "Introduction to Dynamic Systems: Theory, Models, and Applications", *John Wiley & Sons*, New York, 1979.
- M**
- Maghsoudi, M., Z. Mohamed, R. Husain, M. Tokhi, "An Optimal Performance Control Scheme for a 3D Crane", *Mechanical Systems and Signal Processing*, vol. 66-67, no. /, pp. 756-768, 2016.
- MadhusudhanaRao, G., B. SankerRam, "A Neural Network Based Speed Control for DC Motor", *International Journal of Recent Trends in Engineering*, vol. 2, no. 6, pp. 121-124, 2009.
- Masood, M., W. Hew, N. Rahim, "Review of ANFIS-based Control of Induction Motors", *Journal of Intelligent and Fuzzy Systems*, vol. 23, no. 4, pp. 143-158, 2012.
- Mastroianni, G., G. Milovanović, "Interpolation Processes - Basic Theory and Applications", *Springer-Verlag*, Berlin, Heidelberg, 2008.
- Medsker, L. R., "Hybrid Intelligent Systems", *Kluwer Academic Publishers*, Boston, USA, 1995.
- Mehta, S., J. Chiasson, "Nonlinear Control of a Series DC Motor: Theory and Experiment", *IEEE Transactions on Industrial Electronics*, vol. 45, no. 1, pp. 134-141, 1998.

Mendoza, M., A. Zavala-Río, V. Santibáñez, F. Reyes, “A Generalised PID-type Control Scheme with Simple Tuning for the Global Regulation of Robot Manipulators with Constrained Inputs”, *International Journal of Control*, vol. 88, no. 10, pp. 1995-2012, 2012.

Mileris, R., V. Boguslauskas, “Credit Risk Estimation Model Development Process: Main Steps and Model Improvement”, *Engineering Economics*, vol. 22, no. 2, pp. 126-133, 2011.

Milojković, M., D. Antić, M. Milovanović, S. S. Nikolić, S. Perić, M. Almawlawe, “Modeling of Dynamic Systems Using Orthogonal Endocrine Adaptive Neuro-fuzzy Inference Systems”, *Journal of Dynamic Systems, Measurement, and Control*, vol. 137, no. 9, pp. /, 2015.

Milojković, M. T., D. S. Antić, S. S. Nikolić, Z. D. Jovanović, S. Lj. Perić, “On a New Class of Quasi-orthogonal Filters”, *International Journal of Electronics*, vol. 100, no. 10, pp. 1361-1372, 2013.

Milojković, M., S. Nikolić, B. Danković, D. Antić, Z. Jovanović, “Modelling of Dynamical Systems Based on Almost Orthogonal Polynomials”, *Mathematical and Computer Modelling of Dynamical Systems*, vol. 16, no. 2, pp. 133-144, 2010.

Morales-Herrera, R., H. Sira-Ramírez, “Trajectory Tracking for the Magnetic Ball Levitation System via Exact Feedforward Linearization and GPI control”, *International Journal of Control*, vol. 83, no. 6, pp. 1155-1166, 2010.

Mouna, B., S. Lassaad, “Neural Network Speed Controller for Direct Vector Control of Induction Motors”, *International Journal of Engineering Science and Technology*, vol. 2, no. 12, pp. 7470-7480, 2010.

Murray-Smith, R., T. Johansen, “Multiple Model Approaches To Nonlinear Modelling and Control”, *Taylor & Francis*, London, UK, 1997.

## N

Nauck, D., F. Klawonn, R. Kruse, “Foundations of Neuro-Fuzzy Systems”, *John Wiley & Sons*, New York, USA, 1997.

Nayak, P., K. Sudheer, D. Rangan, K. Ramasastri, “A Neuro-fuzzy Computing Technique for Modelling Hydrological Time Series”, *Journal of Hydrology*, vol. 291, no. 1-2, pp. 52–66, 2004.

Negnevitsky, M., “Artificial Intelligence: A Guide to Intelligent Systems”, *Addison-Wesley*, Boston, 2005.

- Nelles, O., "Nonlinear System Identification: From Classical Approaches to Neural Networks and Fuzzy Models", *Springer-Verlag*, Berlin, 2001.
- Nikolić, S., D. Antić, M. Milojković, M. Milovanović, S. Perić, D. Mitić, "Application of Neural Networks with Orthogonal Activation Functions in Control of Dynamical Systems", *International Journal of Electronics*, vol. 103, no. 4, pp. 667-685, 2016a.
- Nikolić, S. S., D. S. Antić, S. Lj. Perić, N. B. Danković, M. T. Milojković, "Design of Generalised Orthogonal Filters: Application to the Modelling of Dynamical Systems", *International Journal of Electronics*, vol. 103, no. 2, pp. 269-280, 2016b.
- Nikolić, S., D. Antić, B. Danković, M. Milojković, Z. Jovanović, S. Perić, "Orthogonal Functions Applied in Antenna Positioning", *Advances in Electrical and Computer Engineering*, vol. 10, no. 4, pp. 35-42, 2010.
- Nikolić, S. S., "Primena Generalizovanih Klasičnih Filtara u Inteligentnim Sistemima Upravljanja", *Univerzitet u Nišu, Elektronski fakultet u Nišu*, 2014.

## O

- O'Dwyer, A., "Handbook of PI and PID Controller Tuning Rules", *Imperial College Press*, London, 2009.

## P

- Palombizio, E., I. Morris, "Forecasting Exchange Rates Using Leading Economic Indicators", *Journal of Stock and Forex Trading*, vol. 1, no. 8, pp. 1-6, 2012.
- Perić, S., D. Antić, M. Milovanović, D. Mitić, M. Milojković, S. Nikolić, "Quasi-sliding Mode Control with Orthogonal Endocrine Neural Network-Based Estimator Applied in Anti-Lock Braking System", *IEEE/ASME Transactions on Mechatronics*, vol. 21, no. 2, pp. 754-764, 2016.
- Peterson, K. S., J. W. Grizzle, A. G. Stefanopoulou, "Nonlinear Control for Magnetic Levitation of Automotive Engine Valves", *IEEE Transactions on Control Systems Technology*, vol. 14, no. 2, pp. 346-354, 2006.
- Philip, A. A., A. A. Taofiki, A. A. Bidemi, "Artificial Neural Network Model for Forecasting Foreign Exchange Rate", *World of Computer Science and Information Technology Journal*, vol. 1, no. 3, pp. 110-118, 2011.
- Pino, R., J. Parreno, A. Gomez, P. Priore, "Forecasting Next-day Price of Electricity in the Spanish Energy Market Using Artificial Neural Networks", *Engineering Applications of Artificial Intelligence*, vol. 21, no. 1, pp. 53-62, 2008.

- Precup, R. E., S. Preitl, "Stability and Sensitivity Analysis of Fuzzy Control Systems", *Mechatronics Applications, Acta Polytechnica Hungarica*, vol. 3, no. 1, pp. 61-76, 2006.
- Precup, R. E., R. C. David, E. M. Petriu, St. Preitl, M. B. Rădac, "Fuzzy Control Systems with Reduced Parametric Sensitivity Based on Simulated Annealing", *IEEE Transactions on Industrial Electronics*, vol. 59, no. 8, pp. 3049-3061, 2012.
- Precup, R.-E., H.-I. Filip, M.-B. Rădac, E. M. Petriu, S. Preitl, C.-A. Dragoș, "Online Identification of Evolving Takagi-Sugeno-Kang Fuzzy Models for Crane Systems", *Applied Soft Computing*, vol. 24, no. /, pp. 1155-1163, 2014.
- Precup, R.-E., C.-A. Bojan-Dragos, E. M. Petriu, M.-B. Radac, A.-I. Stinean, "Results on Optimal Tuning of Fuzzy Models of Magnetic Levitation Systems", *International Journal of Artificial Intelligence*, vol. 13, no. 2, pp. 57-72, 2015.
- Premkumar, K., B. Manikandan, "Fuzzy PID Supervised Online ANFIS Based Speed Controller for Brushless DC Motor", *Neurocomputing*, vol. 157, no. /, pp. 76-90, 2015.

## **Q**

- Qina, Y., H. Penga, F. Zhoua, X. Zenga, J. Wu, "Nonlinear Modeling and Control Approach to Magnetic Levitation Ball System Using Functional Weight RBF Network-based State-dependent ARX Model", *Journal of the Franklin Institute*, vol. 352, no. 10, pp. 4309-4338, 2015.

## **R**

- Rai, N., B. Rai, "Neural Network Based Closed Loop Speed Control of DC Motor using Arduino Uno", *International Journal of Engineering Trends and Technology*, vol. 4, no. 2, pp. 137-140, 2013.
- Riesz, M., "Sur le probleme des moments", *Troisième Note, Arkiv för Matematik, Astronomi och Fysik*, vol. 17, no. 16, pp. 1-52, 1923.

Rumelhart, D., G. Hinton, R. Williams, "Learning Internal Representations by Error Propagation", in *Parallel Distributed Processing*, Rumelhart, D., J. McClelland, Eds., Cambridge MA: MIT Press, vol. 1, no. /, 1986.

## **S**

- Sa'Adah, U., S. S. Saleh, S. Guritno, S. Suhartono, "Wavelet Neural Network Model Selection for Nonlinear-seasonal Time Series Forecasting", *Global Journal of Pure and Applied Mathematics*, vol. 11, no. 1, pp. 137-148, 2015.

Saberi, M., H. Altafi, S. Alizadeh, "Control of the Magnetic Suspension System with a Three-degree-of-freedom Using RBF Neural Network Controller", *International Journal of Computer and Electrical Engineering*, vol. 4, no. 2, pp. 121-126, 2012.

- Sakalas, A., R. Virbickaite, "Construct of the Model of Crisis Situation Diagnosis in a Company", *Engineering Economics*, vol. 22, no. 3, pp. 255-261, 2011.
- Sahin, I., I. Koyuncu, "Design and Implementation of Neural Networks Neurons with RadBas, LogSig, and TanSig Activation Functions on FPGA", *Electronics and Electrical Engineering*, vol. 120, no. 4, pp. 51-54, 2012.
- Sankar, B., D. Kumar, K. Seethalakshmi, "A New Self-adaptive Neuro Fuzzy Inference System for the Removal of Non-linear Artifacts from the Respiratory Signal", *Journal of Computer Science*, vol. 8, no. 5, pp. 621-631, 2012.
- Sauze, C., M. Neal, "Artificial Endocrine Controller for Power Management in Robotic Systems", *IEEE Transactions on Neural Networks and Learning Systems*, vol. 24, no. 12, pp. 1973-1985, 2013.
- Sedra, A. S., W. M. Snelgrove, R. Allen, "Complex Analog Bandpass Filters Designed by Linearly Shifting Real Low-pass Prototypes", *Proceedings of the IEEE International Symposium on Circuits and Systems*, vol. 3, no. /, pp. 1223-1226, 1985.
- Sgaverdea, S., C.-A. Bojan-Dragos, R.-E. Precup, S. Preitl, A.-I. Stinean, "Model Predictive Controllers for Magnetic Levitation Systems", in *Proc. of IEEE 10<sup>th</sup> Jubilee International Symposium on Applied Computational Intelligence and Informatics*, Timisoara, Romania, pp. 171-176, 2015.
- Sher, C., C. Tseng, C. Chen, "Properties and Performance of Orthogonal Neural Network in Function Approximation", *International Journal of Intelligent Systems*, vol. 16, no. 12, pp. 1377-1392, 2001.
- Shen, J., "Fuzzy Neural Networks for Tuning PID Controller for Plants with Underdamped Responses", *IEEE Transactions on Fuzzy Systems*, vol. 9, no. 2, pp. 333-342, 2001.
- Shiakolas, P. S., S. R. Schenck, D. Piyabongkarn, I. Frangeskou, "Magnetic Levitation Hardware-in-the-loop and MATLAB-based Experiments for Reinforcement of Neural Network Control Concepts", *IEEE Transactions on Education*, vol. 47, no. 1, pp. 33-41, 2004.
- Sibi, P., S. A. Jones, P. Siddarth, "Analysis of Different Activation Functions Using Back Propagation Neural Networks", *Journal of Theoretical and Applied Information Technology*, vol. 47, no. 3, pp. 1264-1268, 2013.
- Siegelmann, H., B. Horne, L. Giles, "Computational Capabilities of Recurrent NARX Neural Networks", *IEEE Transactions on Systems, Man, and Cybernetics—PART B: Cybernetics*, vol. 27, no. 2, pp. 208-215, 1997.

Soyguder, S., H. Alli, "An Expert System for the Humidity and Temperature Control in HVAC Systems Using ANFIS and Optimization With Fuzzy Modelling Approach", *Energy and Buildings*, vol. 41, no. 8, pp. 814-822, 2009.

Song, J., W. Cheng, Z. Xu, S. Yuan, M. Liu, "Study on PID Temperature Control Performance of a Novel PTC Material with Room Temperature Curie Point", *International Journal of Heat and Mass Transfer*, vol. 95, no. /, pp. 1038-1046, 2016.

Snelgrove, W. M., A. S. Sedra, "State-space Synthesis of Complex Analog Filters", *Proceedings of the European Conference on Circuit Theory and Design*, Hague, Netherlands, pp. 420-424, 1985.

Szegö, G., "Orthogonal Polynomials", *American Mathematical Society, Colloquium Publications*, Providence, vol. 23, no. /, 1975.

## **T**

Tenti, P., "Forecasting Foreign Exchange Rates Using Recurrent Neural Networks", *Applied Artificial Intelligence*, vol. 10, no. 6, pp. 567-582, 1996.

Timmis, J., M. Neal, J. Thorniley, "An Adaptive Neuro-endocrine System for Robotic Systems", in: *Proceedings of the IEEE Workshop on Robotic Intelligence in Informationally Structured Space*, Nashville, vol. 1, no. /, pp. 129-136, 2009.

Timmis, J., L. Murray, M. Neal, "A Neural-endocrine Architecture for Foraging in Swarm Robotic Systems", in: Gonzales, J. R., D. A. Pelta, C. Cruz, G. Terrazas, N. Krasnogor, (Eds.), *Nature Inspired Cooperative Strategies for Optimization (NISCO 2010), Studies in Computational Intelligence*, Springer Berlin Heidelberg, vol. 284, no. /, pp. 319-330, 2010.

Trajković, D. M., D. S. Antić, S. S. Nikolić, S. Lj. Perić, M. B. Milovanović, "Fuzzy Logic-Based Control of Three-dimensional Crane System", *FACTA UNIVERSITATIS Series: Automatic Control and Robotics*, vol. 12, no. 1, pp. 31-42, 2013.

Tseng, C., S. Yang, "A New Orthogonal Neural Network", *Journal of Chemical Information and Modeling*, vol. 53, no. 9, pp. 296-299.

Tsirigotis, G., D. Bandekas, D. Pogaridis, J. L. Lázaro, "The Anticipatory Aspect in Neural Network Control", *Electronics and Electrical Engineering*, vol. 58, no. 2, pp. 10-13, 2005.

Tyree, E., J. A. Long, "Forecasting Currency Exchange Rates: Neural Networks and the Random Walk Model", *Third International Conference on Artificial Intelligence Applications on Wall Street*, New York, 1995.

**U**

Utkin, V. I., “Sliding Mode Control”, in Variable Structure Systems: From Principles to Implementation”, Sabanovic, A., L. M. Fridman, S. Spurgeon, Eds., pp. 3-17, 2004.

**V**

Vankayala, V., N. Rao, “Artificial Neural Networks and Their Applications to Power Systems - A Bibliographical Survey”, *Electric Power Systems Research*, vol. 28, no. 1, pp. 67-79, 1993.

**W**

Wahab, A., A. Mohamed, “Transient Stability Assessment of Power Systems Using Probabilistic Neural Network with Enhanced Feature Selection and Extraction”, *International Journal on Electrical Engineering and Informatics*, vol. 1, no. 2, pp. 103-114, 2009.

Wang, H., S. Yu, “Tracking Control of Robot Manipulators via Orthogonal Polynomials Neural Network”, *Lecture Notes in Computer Science*, vol. 5553, no. 3, pp. 178-187, 2009.

**Y**

Yang, S., C. Tseng, “An Orthogonal Neural Network for Function Approximation”, *IEEE Transactions on Systems, Man, and Cybernetics – Part B: Cybernetics*, vol. 26, no. 5, pp. 779-785, 1996.

Yogesh, S., M. Gupta, M. Garg, “DC Motor Speed Control using Artificial Neural Network”, *International Journal of Modern Communication Technologies & Research*, vol. 2, no. 2, pp. 19-24, 2014.

Yu, L., S. Wang, K. K. Lai, “Adaptive Smoothing Neural Networks in Foreign Exchange Rate Forecasting”, In *Computational Science–ICCS 2005*, Springer Berlin Heidelberg, pp. 525-530, 2005.

**Z**

Zhang, G., V. Berardi, “Time Series Forecasting With Neural Network Ensembles: An Application for Exchange Rate Prediction”, *Journal of the Operational Research Society*, vol. 52, no. 6, pp. 652-664, 2001.

Zhang, X., Z. Zou, “Black-box Modeling of Ship Manoeuvring Motion Based on Feed-forward Neural Network with Chebyshev Orthogonal Basis Function”, *Journal of Marine Science and Technology*, vol. 18, no. 1, pp. 42-49, 2013.

Zhang, Y., T. Chai, H. Wang, J. Fu, L. Zhang, Y. Wang, “An Adaptive Generalized Predictive Control Method for Nonlinear Systems Based on ANFIS and Multiple Models”, *IEEE Transactions on Fuzzy Systems*, vol. 18, no. 6, pp. 1070-1082, 2010.

- Zhang, Y., W. Li, "Gegenbauer Orthogonal Basis Neural Network and its Weights-direct-determination Method", *Electronics Letters*, vol. 45, no. 23, pp. 4-5, 2009.
- Zhu, X., J. Chen, M. Zhong, "Dynamic Interacting Relationships Among International Oil Prices", *Macroeconomic Variables and Precious Metal Prices, Transactions of Nonferrous Metals Society of China*, vol. 25, no. 2, pp. 669-676, 2015.
- Zou, W., Y. Zhu, L. Cai, "Fourier-neural-network-based Learning Control for a Class of Nonlinear Systems with Flexible Components", *IEEE Transactions on Neural Networks*, vol. 20, no. 1, pp. 139-151, 2009.

## Kratka biografija autora

Miroslav Milovanović, rođen je 06.11.1987. godine u Nišu gde je završio osnovnu školu „Filip Filipović“ odličnim uspehom i bio dobitnik „Vukove diplome“. Gimnaziju „Bora Stanković“ u Nišu, prirodno-matematički smer, završio je 2006. godine sa prosečnom ocenom 4.80 tokom četvorogodišnjeg školovanja. Nakon srednje škole završio je Elektronski fakultet u Nišu na studijskom modulu Upravljanje sistemima 07. oktobra 2011. godine, sa prosečnom ocenom 9,15 (devet i 15/100) čime je stekao zvanje Diplomiranog inženjera elektrotehnike za upravljanje sistemima. U toku studija nagrađivan je poveljama Elektronskog fakulteta za postignute rezultate tokom studiranja (2009. i 2010. godine), bio je dobitnik republičke stipendije za studente sa prosekom preko 8.50 (2009. i 2010. godine) i takođe dobitnik individualne PECD stipendije (2010. godine). Diplomski rad pod nazivom „Automatizovano pranje i dezinfekcija noćnih posuda u zdravstvenim ustanovama“ odbranio je ocenom 10 (deset) 07.10.2011. godine na Elektronskom fakultetu u Nišu. Doktorske studije na Elektronskom fakultetu upisao je 2011. godine, na studijskom modulu Upravljanje sistemima. Dobitnik je stipendije Ministarstva prosvete i nauke za studente doktorskih akademskih studija za naučnu oblast „Elektronika, telekomunikacije i informacione tehnologije“ za 2012. godinu. Kao stipendista Ministarstva bio je raspoređen na naučnoistraživačkom projektu pod nazivom „Istraživanje i razvoj nove generacije vetrogeneratora visoke energetske efikasnosti“. Od novembra 2012. godine radio je kao saradnik u nastavi, a od novembra 2014. godine radi kao asistent na Elektronskom fakultetu u Nišu. U prethodnom periodu držao je auditivne i laboratorijske vežbe iz predmeta: Identifikacija sistema, Modeliranje električnih mašina i pogona, Linearni sistemi automatskog upravljanja, Sistemi automatskog upravljanja, Modeliranje i simulacija dinamičkih sistema, Regulacija elektromotornih pogona, Metode inteligentnog upravljanja i Savremeno upravljanje industrijskim procesima. Objavio je do sada 32 naučna rada u zemlji i inostranstvu, od toga 8 radova u međunarodnim časopisima sa IMPACT faktorom, 8 radova u ostalim međunarodnim časopisima, 9 radova na međunarodnim konferencijama, 2 rada u nacionalnim časopisima, i 5 radova na domaćim konferencijama. Takođe, učestvovao je u izradi jednog tehničkog rešenja. Učestvovao je i u realizaciji jednog projekta finansiranog od strane Ministarstva prosvete, nauke i tehnološkog razvoja Republike Srbije kao stipendista ovog Ministarstva. Takođe, učestvovao je i u realizaciji 5 međunarodnih projekata. Bio je tri puta član Organizacionog odbora međunarodne konferencije *International Conference on Systems, Automatic Control and Measurements – SAUM* u 2012., 2014. i 2016. godini.

# Spisak referenci autora

## a) Kategorija M21 – Radovi objavljeni u vrhunskim međunarodnim časopisima

- a.1 **Miroslav B. Milovanović**, Dragan S. Antić, Marko T. Milojković, Saša S. Nikolić, Staniša Lj. Perić, Miodrag D. Spasić, “Adaptive PID Control Based on Orthogonal Endocrine Neural Network”, *Neural Networks*, vol. 84, pp. 80–90, (Doi No: <http://dx.doi.org/10.1016/j.neunet.2016.08.012>), **Publisher:** Elsevier, December 2016.
- a.2 Staniša Lj. Perić, Dragan S. Antić, **Miroslav B. Milovanović**, Darko B. Mitić, Marko T. Milojković, Saša S. Nikolić, “Quasi-Sliding Mode Control with Orthogonal Endocrine Neural Network-Based Estimator Applied in Anti-Lock Braking System”, *IEEE/ASME Transactions on Mechatronics*, vol. 21, no. 2, pp. 754–764., Print ISSN: 1083-4435, (Doi No: <http://dx.doi.org/10.1109/TMECH.2015.2492682>), **Publisher:** IEEE, April 2016.
- a.3 **Miroslav B. Milovanović**, Dragan S. Antić, Milena N. Rajić, Pedja M. Milosavljević, Ana Pavlović, Cristiano Fragassa, “Wood resource management using an endocrine NARX neural network”, *European Journal of Wood and Wood Products*, (Doi No: <https://doi.org/10.1007/s00107-017-1223-6>), **Publisher:** Springer Berlin Heidelberg, 2017, accepted.

## b) Kategorija M23 – Radovi objavljeni u međunarodnim časopisima

- b.1 **Miroslav B. Milovanović**, Dragan S. Antić, Miodrag D. Spasić, Saša S. Nikolić, Staniša Lj. Perić, Marko T. Milojković, “Improvement of DC Motor Velocity Estimation Using Feedforward Neural Network”, *Acta Polytechnica Hungarica*, vol. 12, no. 6, pp. 107–126., ISSN: 1785-8860, **Publisher:** Óbuda University, Hungary, November 2015.
- b.2 Saša S. Nikolić, Dragan S. Antić, Marko T. Milojković, **Miroslav B. Milovanović**, Staniša Lj. Perić, Darko B. Mitić, “Application of Neural Networks with Orthogonal Activation Functions in Control of Dynamical Systems”, *International Journal of Electronics*, vol. 103, no. 4, pp. 667–685., Print ISSN: 0020-7217, (Doi No: <http://dx.doi.org/10.1080/00207217.2015.1036811>), **Publisher:** Taylor & Francis, April 2016.
- b.3 Marko T. Milojković, Dragan S. Antić, **Miroslav B. Milovanović**, Saša S. Nikolić, Staniša Lj. Perić, Muhanad Almawlawe, “Modeling of Dynamic Systems Using Orthogonal Endocrine Adaptive Neuro-Fuzzy Inference Systems”, *Journal of*

*Dynamic Systems Measurement and Control*, vol. 137, no. 9, ISSN: 1528-9028, (Doi No: <http://dx.doi.org/10.1115/1.4030758>), **Publisher:** American Society of Mechanical Engineers, July 2015.

- b.4 **Miroslav Milovanović**, Dragan Antić, Marko Milojković, Saša S. Nikolić, Miodrag Spasić, Staniša Perić, “Time Series Forecasting with Orthogonal Endocrine Neural Network Based on Postsynaptic Potentials”, *Journal of Dynamic Systems, Measurement, and Control*, vol. 139, no. 4, pp. 041006-1–041006-9, DS-15-1656, Print ISSN: 0022-0434, (Doi No: <http://dx.doi.org/10.1115/1.4035090>), **Publisher:** The American Society of Mechanical Engineers, April 2017.
- b.5 **Miroslav B. Milovanović**, Dragan S. Antić, Saša S. Nikolić, Staniša Lj. Perić, Marko T. Milojković, Miodrag D. Spasić, “Neural Network Based on Orthogonal Polynomials Applied in Magnetic Levitation System Control”, *Electronics and Electrical Engineering*, vol. 23, no. 3, (2017), pp. 24–29. Print ISSN: 1392-1215, (Doi No: <http://dx.doi.org/10.5755/j01.eie.23.3.18327>), Publisher: Kaunas University of Technology, June 2017.

**c) Kategorija M24 – Radovi objavljeni u međunarodnim časopisima verifikovani posebnim odlukama**

- c.1 Nikola Danković, Darko Mitić, Marko Milojković, Stanko Stankov, **Miroslav Milovanović**, “Thermodynamic Model of the Protector Cooling System with Applications”, *FACTA UNIVERSITATIS Series: Electronics and Energetics*, vol. 26, no. 1, pp. 53–60., Print ISSN: 0353-3670, **Publisher:** University of Niš, 2013.
- c.2 Staniša Perić, Dragana Trajković, Dragan Antić, Vlastimir Nikolić, Saša S. Nikolić, **Miroslav Milovanović**, “Fuzzy-PI Control of Water Pumps Modelled by Hybrid Bond Graphs”, *FACTA UNIVERSITATIS Series: Automatic Control and Robotics*, vol. 14, no. 1, pp. 29–42., Print ISSN: 1820-6417, **Publisher:** University of Niš, 2015.
- c.3 **Miroslav B. Milovanović**, Dragan S. Antić, Saša S. Nikolić, Miodrag D. Spasić, Staniša Lj. Perić, Marko T. Milojković, “Data Denoising Procedure for Neural Network Performance Improvement”, *FACTA UNIVERSITATIS Series: Automatic Control and Robotics*, vol. 14, no. 3, pp. 173–182., Print ISSN: 1820-6417, **Publisher:** University of Niš, 2015.

**d) Kategorija M33 – Saopštenja sa međunarodnih skupova**

- d.1 Stanko Stankov, Saša Arsić, **Miroslav Milovanović**, Milan Radić, Zoran Icić, “Work Regulation of Plant for Preparation and Dosing Aluminum Sulphate in Water Systems”, *Proceedings of the XI International Conference on Systems, Automatic Control and Measurements, SAUM 2012*, Niš, Serbia, November 14<sup>th</sup>-16<sup>th</sup>, pp. 40–43, ISSN: 978-86-6125-072-9, **Publisher:** Faculty of Electronic Engineering, Niš, Faculty of Mechanical Engineering, Niš, Serbia, 2012.

- d.2 Saša Arsić, Stanko Stankov, Nikola Danković, **Miroslav Milovanović**, Zoran Icić, “The Usage of Mobile Communications for SCADA Systems Data Transmission”, *Proceedings of the XI International Conference on Systems, Automatic Control and Measurements, SAUM 2012*, Niš, Serbia, November. 14<sup>th</sup>-16<sup>th</sup>, pp. 427–430, ISSN: 978-86-6125-072-9, *Publisher: Faculty of Electronic Engineering, Niš, Faculty of Mechanical Engineering, Niš, Serbia*, 2012.
- d.3 Peđa Milosavljević, Milena Todorović, **Miroslav Milovanović**, Dragan Pavlović, “Problems of the Small Passing Exams at Faculty of Mechanical and Electronic Engineering”, *International Conference on Application of Information and Communication Technology and Statistics in Economy and Education (ICAICTSEE – 2012)*, october 5-6<sup>th</sup>, vol. 200, pp. 146–156., ISBN: 978-954-92247-4-0, *Publisher: University Of National and World Economy, Sofia, Bulgaria*, 2012.
- d.4 **M. Milovanović**, D. Antić, S. Perić, S. S. Nikolić, M. Milojković, N. Danković, “Artificial Approach for Achieving Two Position Levitation Motion of Magnetic Levitation System”, *Proceedings of the XII International Conference on Systems, Automatic Control and Measurements, SAUM 2014*, Niš, Serbia, November 12.-14., pp. 168–171., (ISBN: 978-86-6125-117-7), *Publisher: Faculty of Electronic Engineering, Niš, Faculty of Mechanical Engineering, Niš, Serbia*, 2014.
- d.5 S. S. Nikolić, D. Trajković, D. Antić, V. Nikolić, S. Perić, **M. Milovanović**, “Fuzzy Control Applied on the Three Parallel Pumps Modelled by Bond Graphs”, *Proceedings of the XII International Conference on Systems, Automatic Control and Measurements, SAUM 2014*, Niš, Serbia, November 12.-14., pp. 171–175., (ISBN: 978-86-6125-117-7), *Publisher: Faculty of Electronic Engineering, Niš, Faculty of Mechanical Engineering, Niš, Serbia*, 2014.
- d.6 M. T. Milojković, **M. B. Milovanović**, D. B. Mitić, S. Lj. Perić, M. D. Spasić, S. S. Nikolić, “Improving Woodworking Industry Through Implementation of IPA Project ADRIA HUB”, *Proceedings of the XII International Conference on Systems, Automatic Control and Measurements, SAUM 2014*, Niš, Serbia, November 12.-14., pp. 380–382., (ISBN: 978-86-6125-117-7), *Publisher: Faculty of Electronic Engineering, Niš, Faculty of Mechanical Engineering, Niš, Serbia*, 2014.
- d.7 Marko Milojković, Dragan Antić, **Miroslav Milovanović**, Staniša Perić, Saša S. Nikolić, Darko Mitić, Marko Živković, “Time Series Forecasting Using Endocrine Neural Network”, *Proceedings of the XIII International Conference on Systems, Automatic Control and Measurements, SAUM 2016*, Niš, Serbia, November 09.-11., pp. 71–74., (ISBN: 978-86-6125-170-2), *Publisher: Faculty of Electronic Engineering, Niš, Faculty of Mechanical Engineering, Niš, Serbia*, 2016.
- d.8 Saša S. Nikolić, Dragan Antić, Staniša Perić, Nikola Danković, Miodrag Spasić, **Miroslav Milovanović**, “Hybrid-Fuzzy Controllers Applied in DC Servo Drive”, *Proceedings of the XIII International Conference on Systems, Automatic Control and Measurements, SAUM 2016*, Niš, Serbia, November 09.-11., pp. 128–131., (ISBN: 978-86-6125-170-2), *Publisher: Faculty of Electronic Engineering, Niš, Faculty of Mechanical Engineering, Niš, Serbia*, 2016.

- d.9 Nikola Danković, Dragan Antić, Saša S. Nikolić, Staniša Perić, Marko Milojković, **Miroslav Milovanović**, “New Classes of the Orthogonal Polynomials - An Overview”, *Proceedings of the XIII International Conference on Systems, Automatic Control and Measurements, SAUM 2016*, Niš, Serbia, November 09.-11., pp. 221–224., (ISBN: 978-86-6125-170-2), *Publisher: Faculty of Electronic Engineering, Niš, Faculty of Mechanical Engineering, Niš, Serbia*, 2016.

**e) Kategorija M52 – Radovi u časopisima nacionalnog značaja**

- e.1 Dragan Antić, **Miroslav Milovanović**, Saša Nikolić, Marko Milojković, Staniša Perić, “Simulation Model of Magnetic Levitation Based on NARX Neural Networks”, *International Journal of Intelligent Systems and Applications*, vol. 5, no. 5, pp. 25–32, Print ISSN: 2074-904X, *Publisher: Modern Education & Computer Science Press, Hong Kong*, 2013.
- e.2 Dragan Antić, **Miroslav Milovanović**, Saša Nikolić, Staniša Perić, Marko Milojković, “Primena NARX Neuronske Mreže za Simulaciju Rada Sistema Magnetne Levitacije”, *Časopis TEHNIKA*, UDC: 62, pp. 473–479, ISSN: 0040-2176, *Publisher: Savez Inženjera i Tehničara Srbije, Beograd (in Serbian)*, Jun 2013.
- e.3 Dragana M. Trajković, Dragan S. Antić, Saša S. Nikolić, Staniša Lj. Perić, **Miroslav B. Milovanović**, “Fuzzy Logic-based Control of Three-dimensional Crane System”, *FACTA UNIVERSITATIS Series: Automatic Control and Robotics*, vol. 12, no. 1, pp. 31–42., Print ISSN: 1820-6417, *Publisher: University of Niš*, July 2013.
- e.4 Stanko Stankov, **Miroslav Milovanović**, Nikola Danković, “SCADA System of Plant for Preparation and Dosing Aluminum Sulphate in Water Systems”, *Transaction on Electrical and Electronic Circuits and Systems*, vol. 3, no. 2, pp. 73–79, pdf version available on: (<http://www.tsest.org/index.php/TEECS/article/view/199/123>), November 2013.
- e.5 Dragan Antić, **Miroslav Milovanović**, Staniša Perić, Saša Nikolić, Marko Milojković, “Input Data Preprocessing Method for Exchange Rate Forecasting via Neural Network”, *Serbian Journal of Electrical Engineering*, vol. 11, no. 4, pp. 597–608, December 2014.
- e.6 **Miroslav Milovanović**, Dragan Antić, Saša Nikolić, Staniša Perić, Marko Milojković, Darko Mitić, “Empirical Training Process Selection for Three Layer Feedforward Neural Network Learning Procedure”, *International Journal of Artificial Intelligence and Knowledge Discovery*, vol. 5, no. 1, pp. 9–13, Print-ISSN: 2231-2021, *Publisher: RG Education Society (India)*, 2015.
- e.7 Marko Milojković, **Miroslav Milovanović**, Darko Mitić, Staniša Perić, Miodrag Spasić, Saša Nikolić, “Laboratory CNC Machine for Education of Students in Control Systems Engineering”, *FACTA UNIVERSITATIS Series: Automatic Control and Robotics*, vol. 13, no. 2, pp. 117–125, Print ISSN: 1820-6417, *Publisher: University of Niš*, 2014.

## **f) Kategorija M63 – Zbornici skupova nacionalnog značaja**

- f.1 Milena Todorović, Peđa Milosavljević, Dragan Pavlović, **Miroslav Milovanović**, “Comparative Analysis of the Passing exams at Faculty of Electronic and Mechanical Engineering”, *Majska konferencija o strategijskom menadžmentu, Bor*, vol. 1, no. 0, pp. 808–818., ISSN: 978-86-80987-96-5, *Publisher: Univerzitet u Beogradu, Tehnički fakultet u Boru, Odsek za menadžment (In Serbian)*, 2012.
- f.2 **Miroslav Milovanović**, Zoran Jovanović, Marko Milojković, Miodrag Spasić, Dejan Mitić, “Realizacija Upravljačke Logike kod Uređaja za Pranje i Dezinfekciju Posuda u Medicinskim Ustanovama”, *Zbornik 57. konferencije ETRAN, Zlatibor*, str. AU4.3.1-4, Print ISBN: 978-86-80509-68-6, *Publisher: Društvo za ETRAN (In Serbian)*, Jun 2013.
- f.3 Nikola Danković, Darko Mitić, Marko Milojković, Stanko Stankov, **Miroslav Milovanović**, “Termodinamički Model Sistema za Hlađenje Protektora i Njegova Primena”, *Zbornik 57. konferencije ETRAN, Zlatibor*, str. AU5.4.1-4, Print ISBN: 978-86-80509-68-6, *Publisher: Društvo za ETRAN (In Serbian)*, Jun 2013.
- f.4 **Miroslav Milovanović**, Dragan Antić, Ljilja M. Antić, Saša S. Nikolić, Marko Milojković, “Metoda za Selekciju Ulaznih Parametara Veštačke Neuronske Mreže”, *Zbornik 58. konferencije ETRAN, Vrnjačka Banja*, str. AU1.4.1-5, *Publisher: Društvo za ETRAN (In Serbian)*, Jun 2014.
- f.5 Nikola Danković, Zoran Perić, Stanko Stankov, **Miroslav Milovanović**, Dejan Mitić, “Analiza Osetljivosti Rekurzivnog Filtra sa Prediktorom i-tog Reda u DPCM Sistemu”, *Zbornik 58. konferencije ETRAN, Vrnjačka Banja*, str. AU1.5.1-4, *Publisher: Društvo za ETRAN (In Serbian)*, Jun 2014.

## **g) Kategorija M82 – Tehnička i razvojna rešenja**

- g.1 Dragan Antić, Zoran Icić, Zoran Jovanović, Vlastimir Nikolić, Žarko Ćojbašić, Saša Nikolić, Staniša Perić, **Miroslav Milovanović**, Dejan Mitić, Ivan Ćirić, “Trofazni pretvarač napona”, Elektronski fakultet u Nišu, Odluka broj: 07/10-025/13-001, 21.03.2013.



---

## Prilog 1.

Izjava 1.

### **IZJAVA O AUTORSTVU**

Izjavljujem da je doktorska disertacija, pod naslovom

**Upravljanje dinamičkim sistemima primenom adaptivnih ortogonalnih neuronskih mreža**

koja je odbranjena na Elektronskom fakultetu Univerziteta u Nišu:

- rezultat sopstvenog istraživačkog rada;
- da ovu disertaciju, ni u celini, niti u delovima, nisam prijavljivao na drugim fakultetima, niti univerzitetima;
- da nisam povredio autorska prava, niti zloupotrebio intelektualnu svojinu drugih lica.

Dozvoljavam da se objave moji lični podaci, koji su u vezi sa autorstvom i dobijanjem akademskog zvanja doktora nauka, kao što su ime i prezime, godina i mesto rođenja i datum odbrane rada, i to u katalogu Biblioteke, Digitalnom repozitorijumu Univerziteta u Nišu, kao i u publikacijama Univerziteta u Nišu.

U Nišu, 29.08.2017.

Autor disertacije: Miroslav B. Milovanović, dipl. inž.

Potpis autora disertacije:

---



---

**Prilog 1.**

Izjava 2.

## **IZJAVA O ISTOVETNOSTI ŠTAMPANOG I ELEKTRONSKOG OBЛИKA DOKTORSKE DISERTACIJE**

Ime i prezime autora: **Miroslav B. Milovanović**

Naslov rada: **Upravljanje dinamičkim sistemima primenom adaptivnih ortogonalnih  
neuronskih mreža**

Mentor: **prof. dr Dragan S. Antić**

Izjavljujem da je štampana verzija moje doktorske disertacije istovetna elektronskoj  
verziji, koju sam predao za unošenje u **Digitalni repozitorijum Univerziteta u Nišu**.

U Nišu, 29.08.2017.

Autor disertacije: Miroslav B. Milovanović, dipl. inž.

Potpis autora disertacije:

---



---

## Prilog 1.

Izjava 3.

### IZJAVA O KORIŠĆENJU

Ovlašćujem Univerzitetsku biblioteku „Nikola Tesla“ da, u Digitalni repozitorijum Univerziteta u Nišu, unese moju doktorsku disertaciju, pod naslovom:

#### **Upravljanje dinamičkim sistemima primenom adaptivnih ortogonalnih neuronskih mreža**

Disertaciju sa svim prilozima predao sam u elektronskom obliku, pogodnom za trajno arhiviranje.

Moju doktorsku disertaciju, unetu u Digitalni repozitorijum Univerziteta u Nišu, mogu koristiti svi koji poštuju odredbe sadržane u odabranom tipu licence Kreativne zajednice (Creative Commons), za koju sam se odlučio.

1. Autorstvo (CC BY)
2. Autorstvo – nekomercijalno (CC BY-NC)
3. Autorstvo – nekomercijalno – bez prerade (CC BY-NC-ND)
4. Autorstvo – nekomercijalno – deliti pod istim uslovima (CC BY-NC-SA)
5. Autorstvo – bez prerade (CC BY-ND)
6. Autorstvo – deliti pod istim uslovima (CC BY-SA)

U Nišu, 29.08.2017.

Autor disertacije: Miroslav B. Milovanović, dipl. inž.

Potpis autora disertacije:

---