



Miljković, K., Petrović, M.M., Jovanović, R.¹⁾

PRIOLOG RAZVOJU INTELIGENTNOG UPRAVLJANJA SERVO MOTORA JEDNOSMERNE STRUJE PRIMENOM VEŠTAČKIH NEURONSKIH MREŽA²⁾

Rezime

U radu je prikazan mogući pristup inteligentnog upravljanja servo motora jednosmerne struje korišćenjem veštačkih neuronskih mreža. Pored primene jedne od najzastupljenijih tehnika veštačke inteligencije, u radu je predloženo i dato matematičko modelovanje ovog široko zastupljenog objekta automatskog upravljanja. Takođe, u cilju prevazilaženja nedostataka vezanih za konvencionalno upravljanje servo motora jednosmerne struje, u radu su iskorišćene sposobnosti veštačkih neuronskih mreža da mogu da generalizuju i aproksimiraju izlaze ovog objekta primenom mašinskog učenja kroz proces njihovog obučavanja. Predloženi pristup, prvo je analiziran putem simulacije, a potom je i eksperimentalno verifikovan na primeru dva od četiri modela koji su razmatrani.

Ključne reči: *inteligentno upravljanje, servo motor jednosmerne struje, veštačke neuronske mreže, mašinsko učenje, matematičko modelovanje*

1. UVOD

Inteligentni sistemi upravljanja [2] predstavljaju naprednu naučnu multidisciplinarnu oblast koja ima intenzivan razvoj u 21. veku. Multidisciplinarnost obuhvata razvoj i primenu prvenstveno sledećih naučnih disciplina: automatskog upravljanja [3], veštačke inteligencije [5] i matematičkog modelovanja objekata [1, 2, 3]. Cilj ovog rada je vezan za naučno-istraživačku potrebu autora da se sagleda mogućnost primene veštačkih neuronskih mreža [5] pri inteligentnom upravljanju servo motora jednosmerne struje [7].

Danas, posebno u domenu inteligentnog upravljanja DC servo motora [1, 2], neophodno je bilo da se posebno razmotri mogućnost identifikacije, odnosno modelovanja i upravljanja izlaza ovog objekta korišćenjem jedne od najzastupljenijih tehnika veštačke inteligencije, veštačkih neuronskih mreža [5]. Veštačke neuronske mreže imaju sposobnost generalizacije i aproksimacije izlaza objekta primenom mašinskog učenja, i to kroz proces njihovog obučavanja korišćenjem širokog spektra dostupnih algoritama [6]. Jedan od najčešće primenjivanih je backpropagation (BP) algoritam učenja sa povratnim prostiranjem greške [5], koji je i primenjen u ovom radu.

Istraživanje, prikazano u ovom radu, podrazumevalo je modelovanje objekta, uz simulaciju i eksperimentalnu verifikaciju dobijenog modela objekta (DC motor), kao i realizaciju inteligentnog upravljanja tog servo motora jednosmerne struje, primenom neuronskih mreža, i to korišćenjem dva od četiri razmatrana modela [2, 4].

2. KOMPONENTE SISTEMA

Za eksperimentalnu realizaciju rada korišćen je Quanser SRV02 [7], rotacioni servo objekt, prikazan na slici 1, a koji se sastoji od servo motora jednosmerne struje (DC motor), smeštenog u aluminijsko kućište, kao i od potenciometra, tahometra i enkodera. Tahometar se koristi za merenje ugaone brzine, dok potenciometar i enkoder vrše merenje ugaone pozicije. Za dobijanje eksperimentalnih rezultata, u radu je korišćen isključivo

¹⁾ MSc Katarina Miljković, istraživač pripravnik, Univerzitet u Beogradu-Mašinski fakultet, kmiljkovic@mas.bg.ac.rs,
dr Milica M. Petrović, docent, Univerzitet u Beogradu - Mašinski fakultet, mmpetrovic@mas.bg.ac.rs,
dr Radiša Jovanović, vanredni profesor, Univerzitet u Beogradu - Mašinski fakultet, rjovanovic@mas.bg.ac.rs.

²⁾ Rad je nastao u okviru istraživanja na potprojektu: „Integrirana istraživanja u oblasti makro, mikro i nano mašinskog inženjerstva - Duboko mašinsko učenje inteligentnih tehnoloških sistema u proizvodnom mašinstvu“ koji finansira Ministarstvo prosvete, nauke i tehnološkog razvoja Vlade Republike Srbije (ugovor br. 451-03-68/2020-14/200105), kao i na projektu VI - MISSION4.0 (evidencioni broj: 6523109) koji je finansijski podržan od strane Fonda za nauku Republike Srbije, 2020.

tahometar [4], koji je direktno priključen na DC motor. Na taj način se sprečava bilo kakvo kašnjenje u vremenu i osigurava da se ugaona brzina motora utvrđuje sa višom tačnošću. Naime, dobija se naponski signal koji je proporcionalan ugaonoj brzini. Motor ima reduktor sa spoljašnjim zupčanicima. Kao opterećenje ovog DC motora, postavljen je disk mase 0.04kg i prečnika 0.05m (slika 1). Prosleđivanje signala sa računara ka DC servo motoru, kao i sa senzora ka računaru, omogućeno je akvizicionom karticom [9], dok se napajanje senzora i pojačavanje signala vrši pomoću pojačavača [10].



Slika 1. Servo motor Quanser SRV02 sa izabranom konfiguracijom zupčanika [7] (a), primer postavljanja opterećenja [7] (b), akviziciona kartica [9] (c) i pojačavač [10] (d)


3. MATEMATIČKI MODEL OBJEKTA

Uopšteno posmatrano, ugaona brzina vratila DC servo motora, u odnosu na ulazni napon motora, može biti opisana pomoću sledeće prenosne funkcije prvog reda:

$$\frac{\Omega_l(s)}{V_m(s)} = \frac{K}{\tau s + 1'} \quad (1)$$

gde je $\Omega_l(s)$ Laplasova transformacija ugaone brzine vratila, $V_m(s)$ Laplasova transformacija ulaznog napona motora, K poziciono pojačanje, τ vremenska konstanta, a s kompleksna promenljiva.

Prikaz armature namotaja i sklopa zupčanika, korišćenog servo motora Quanser SRV02, vidi se na slici 2. Električni deo podrazumeva napon izvora napajanja V_m , kontra elektromotornu silu e_b , rednu vezu otpornika otpornosti R_m i kalema induktivnosti L_m , dok je mehanički deo predstavljen momentom inercije motora J_m , čije se vratilo rotira ugaonom brzinom ω_m stvarajući obrtni moment τ_m . Preko zupčastih parova N_1, N_2 i N_3, N_4 , ugaona brzina ω_m i obrtni moment τ_m postaju ω_l i τ_l , a koji pokreću i opterećenje momenta inercije J_l .



Slika 2. Prikaz armature namotaja i sklopa zupčanika servo motora SRV02 [8]

U nastavku ovog rada, daje se detaljniji matematički model posmatranog objekta, kroz električne i mehaničke jednačine [8].

3.1 Električne jednačine

Elektromotorna sila $e_b(t)$ zavisi od ugaone brzine vratila motora ω_m i konstante motora k_m . Ona se suprotstavlja trenutnom toku struje i data je jednačinom:

$$e_b(t) = k_m \omega_m(t), \quad (2)$$

gde je k_m koeficijent elektromotorne sile, a ω_m ugaona brzina vratila motora.

Koristeći Kirhofov zakon moguće je napisati sledeću jednačinu:

$$V_m(t) - R_m I_m(t) - L_m \frac{dI_m(t)}{dt} - k_m \omega_m(t) = 0, \quad (3)$$

gde je V_m napon armaturnog namotaja, I_m struja armaturnog namotaja, R_m električna otpornost armaturnog namotaja i L_m koeficijent induktivnosti armaturnog namotaja.

S obzirom da je indukcija motora L_m mnogo manja od njegove otpornosti, ona može biti zanemarena. Na osnovu toga dobija se izraz za struju motora:

$$V_m(t) - R_m I_m(t) - k_m \omega_m(t) = 0, \quad (4)$$

$$I_m(t) = \frac{V_m(t) - k_m \omega_m(t)}{R_m}. \quad (5)$$

3.2 Mehaničke jednačine

Jednačina ulaznog vratila (vratila motora) data je kao:

$$J_m \frac{d\omega_m(t)}{dt} + B_m \omega_m(t) + \tau_{ml}(t) = \tau_m(t), \quad (6)$$

dok je jednačina izlaznog vratila:

$$J_l \frac{d\omega_l(t)}{dt} + B_l \omega_l(t) = \tau_l(t), \quad (7)$$

gde J_m, J_l predstavljaju momente inercije motora i opterećenja, sledstveno, ω_m, ω_l ugaone brzine vratila motora i izlaznog vratila, τ_m, τ_l obrtne momente vratila motora i izlaznog vratila, B_m, B_l koeficijente viskoznog trenja motora i prenosnika, dok je τ_{ml} obrtni moment sveden na vratilo motora.

Obrtni moment na izlaznom vratilu se može napisati kao:

$$\tau_l(t) = \eta_g K_g \tau_{ml}(t), \quad (8)$$

gde η_g predstavlja stepen iskorišćenja, a K_g prenosni odnos zupčanika na servo motoru.

Diferencijalna jednačina koja opisuje kretanje izlaznog vratila data je u pojednostavljenom obliku:

$$J_{eq} \frac{d\omega_l(t)}{dt} + B_{eq} \omega_l(t) = \eta_g K_g \tau_m(t). \quad (9)$$

3.3 Redukovani linearni matematički model objekta

Obrtni moment motora proporcionalan je ulaznom naponu, a opisuje se sa:

$$\tau_m(t) = \eta_m k_t I_m(t), \quad (10)$$

gde η_m predstavlja stepen iskorišćenja motora, k_t trenutnu konstantu obrtnog momenta, a I_m jačinu struje.

Ukoliko se obrtni moment motora izrazi pomoću ulaznog napona V_m i ugaone brzine izlaznog vratila ω_l , zamenjujući ranije dobijene izraze za jačinu struje I_m i ugaonu brzinu vratila motora ω_m i koristeći diferencijalnu jednačinu koja opisuje kretanje izlaznog vratila, dobija se:

$$J_{eq} \frac{d\omega_l(t)}{dt} + \left(\frac{k_m \eta_g K_g^2 \eta_m k_t}{R_m} + B_{eq} \right) \omega_l(t) = \frac{\eta_g K_g \eta_m k_t V_m(t)}{R_m}. \quad (11)$$

Ukoliko je ekvivalentni koeficijent prigušenja dat kao:

$$B_{eq,v} = \frac{k_m \eta_g K_g^2 \eta_m k_t + B_{eq} R_m}{R_m}, \quad (12)$$

dok je pojačanje:

$$A_m = \frac{\eta_g K_g \eta_m k_t}{R_m}, \quad (13)$$

jednačina (11) postaje:

$$J_{eq} \frac{d\omega_l(t)}{dt} + B_{eq,v} \omega_l(t) = A_m V_m(t). \quad (14)$$

Dobijena jednačina predstavlja konačni oblik diferencijalne jednačine koja opisuje kretanje izlaznog vratila i može se zapisati u obliku:


$$J_{eq} \dot{x}_i(t) + B_{eq,v} x_i(t) = A_m x_u(t). \quad (15)$$

Pod pretpostavkom da se zazor u prenosniku može zanemariti, dobija se linearni matematički model objekta, predstavljen blok dijagramom na slici 3. Sada je moguće prikazati prenosnu funkciju sistema koja predstavlja količnik levih Laplasovih transformacija njegove izlazne i ulazne veličine, pri svim početnim vrednostima jednakim nuli. Primenom leve Laplasove transformacije na dobijenu diferencijalnu jednačinu ponašanja u vremenskom domenu, dobija se njen oblik u kompleksnom domenu:

$$J_{eq} s X_i^-(s) + B_{eq,v} X_i^-(s) = A_m X_u^-(s), \quad (16)$$

na osnovu koje sledi prenosna funkcija sistema:


$$W(s) = \frac{X_i^-(s)}{X_u^-(s)} = \frac{A_m}{J_{eq} s + B_{eq,v}}. \quad (17)$$



Slika 3. Blok dijagram linearnog sistema [4]

3.4 Eksperimentalna verifikacija dobijenog linearnog modela

Nakon snimljenih podataka dobijenih simulacijom linearnog modela i stvarnog odziva objekta, izvršena su poređenja prikazana na slikama 4 i 5.




Slika 4. Poređenje signala dobijenog simulacijom (plavo) i odziva objekta na dati odskočni signal (crveno) [4]

Ukoliko je promena ulazne veličine zadata odskočnom funkcijom, odziv simulacije i stvarnog objekta, za veću konstantnu vrednost, vidno će odstupati. Odzivi objekta i simulacionog modela na sinusnu pobudu (slika 5, levo) ne poklapaju se u potpunosti, što se bolje može primetiti na slici 5 (desno), gde je dat uvećan prikaz područja oko nule i jasno se vidi da postoji nelinearnost pri stvarnom radu servo motora.

Nakon izvršenih eksperimenata utvrđeno je da stvarno ponašanje objekta nije linearno, tačnije linearni model ne opisuje dovoljno dobro ponašanje objekta u celom prostoru izlaza. Osnovni uzrok je trenje, za sve navedeno. Umesto linearnog člana $B_{eq,v}\omega_l$ uvodi se nelinearna funkcija, a ne ulazeći u matematički opis nelinearnosti, može se označiti kao $M_{TR}(\omega_l)$. Smatrajući ω_l izlaznom veličinom, moment trenja se može predstaviti nelinearnošću $N(x_i)$. Diferencijalna jednačina ponašanja tada postaje:

$$J_{eq}\dot{x}_i(t) + N(x_i(t)) = A_m x_u(t). \quad (18)$$



Slika 5. Simulacioni (plavo) i eksperimentalni (crveno) odziv objekta na sinusnu pobudu (levo) i uvećan detalj u području oko nule (desno) [4]

S obzirom da je objekt nelinearan i da linearni model ne opisuje dobro dinamičko ponašanje servo motora, očitu nelinearnost je moguće rešiti primenom veštačkih neuronskih mreža, što je u ovom radu i prikazano.

4. VEŠTAČKE NEURONSKE MREŽE

Pri modelovanju i upravljanju sistemima i procesima uglavnom se pretpostavlja da opšti, analitički model sistema može da se definiše. Međutim, postoje kompleksni sistemi kao i mnogi procesi koji su toliko komplikovani da se opšti model retko kada može uspostaviti. Dakle, nastaje problem vezan za mogućnosti modelovanja i predviđanja ponašanja pojedinih sistema u situacijama kada se njihovo ponašanje temelji na potpuno stohastičkim pojavama. U takvim slučajevima, veštačke neuronske mreže se mogu koristiti kao univerzalni aproksimatori [2, 5, 6]. Veštačke neuronske mreže imaju sposobnost adaptivnog ponašanja prema promenama, kroz učenje ulaznog uzorka, jer mogu da uče preslikavanje između ulaznog i izlaznog prostora.

Sa stanovišta teorije sistema [2], neuron se može posmatrati kao višestruko prenosni sistem, tj. kao sistem sa više ulaza (n -dimenzionalni vektor ulaza $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_n]^T$) i jednim izlazom (skalar $y \in \mathcal{R}$). Vektor ulaza $\mathbf{x} \in \mathcal{R}^n$ predstavlja signale koji se prenose sa okolnih neurona na posmatrani neuron. Veličina izlaza, koju posmatrani neuron dobija od drugih (ulaz za posmatrani neuron), zavisi od jačine veza i ona je određena težinskim odnosom koji se pridružuje svakoj takvoj vezi, te je moguće odrediti vektor težinskih koeficijenata, tj. vektor težinskih odnosa ($\mathbf{w} = [\omega_1 \ \omega_2 \ \dots \ \omega_n]^T$). Parametar θ predstavlja prag osetljivosti neurona, koji omogućava dalje generisanje signala, ukoliko je njihova vrednost veća od njegove. Matematički posmatrano, sposobnost obrade informacija unutar neurona, može se predstaviti nelinearnim preslikavanjem vektora \mathbf{x} u skalar y , koje se deli na ulazno preslikavanje i operaciju nelinearne aktivacije. Ulazno preslikavanje predstavlja skalarni proizvod vektora \mathbf{x} i \mathbf{w} , tj. preslikavanje iz n -dimenzionalnog ulaznog prostora neurona u jednodimenzionalni prostor, $v \in \mathcal{R}$. Veličina v se naziva aktivaciona vrednost neurona i definiše se kao:

$$v = \mathbf{w}^T \mathbf{x} - \theta = \sum_{i=1}^n \omega_i x_i - \theta. \quad (19)$$

Da bi veštačka neuronska mreža izvršila neki postavljeni zadatak, potrebno je povezati neurone u odgovarajuću konfiguraciju, postaviti težinske odnose između neurona i izabrati ulazno-izlaznu funkciju [5]. Osnovni princip rada mreže podrazumeva da se raspoloživi podaci (npr. veličine stanja signala) prosleđuju ulaznom sloju mreže, s obzirom da vrednosti signala koje primaju neuroni u skrivenom sloju zavise od modifikacije ulaznog signala, a predstavljene su jačinama veza između neurona, kao i time na koji način će tako formiran ulaz u neuron biti promenjen izborom odgovarajuće aktivacione funkcije u neuronu.

Stvaranje, odnosno konfigurisanje veštačke neuronske mreže obuhvata četiri faze [5]:

- sprovođenje eksperimenata (prikupljanje ulaznih veličina stanja signala, za obučavanje i testiranje);
- projektovanje mreže (definisane svega što mrežu određuje: broj slojeva u mreži, aktivacione funkcije, algoritam učenja, itd.);
- povezivanje neurona u svakom od slojeva;
- implementacija (pretvaranje ulaznih veličina u željeni format, pretprocesiranje podataka, testiranje rada mreže).

Algoritam učenja sa povratnim prostiranjem greške (*backpropagation*, BP), primenjen je na višeslojne neuronske mreže bez povratnih veza, koje se sastoje od procesirajućih elemenata sa neprekidnim, diferencijabilnim aktivacionim funkcijama [2]. Za dati obučavajući skup, tj. skup ulazno-izlaznih parova $\mathbf{x}^{(k)}$, $\mathbf{d}^{(k)}$, $k = 1, 2, \dots, p$, algoritam učenja obezbeđuje proceduru za promenu težinskih odnosa u BP mreži, kao i za klasifikovanje ulaznih uzoraka. Osnova za podešavanje težinskih odnosa je gradijentna metoda. Za dati ulazno-izlazni par $(\mathbf{x}^{(k)}, \mathbf{d}^{(k)})$, kod BP algoritma učenja se mogu uočiti dve faze toka informacija, tj. signala. Prvo, ulazni uzorak \mathbf{x} se prostire od ulaznog sloja do izlaznog i kao rezultat ovog toka signala unapred, na izlazu mreže se generiše odgovarajući izlaz. Tada se signali greške koji predstavljaju razliku između $\mathbf{d}^{(k)}$ i $\mathbf{y}^{(k)}$, prostiru unazad od izlaznog sloja do prethodnog, a koriste se i za podešavanje njihovih težinskih odnosa.

5. IDENTIFIKACIJA SISTEMA I INTELIGENTNO UPRAVLJANJE

Primena veštačkih neuronskih mreža u upravljanju je veoma atraktivna zbog njihove sposobnosti da uče, aproksimiraju funkcije i klasifikuju uzorke, kao i mogućnosti za masovnu paralelnu hardversku implementaciju. One imaju sposobnost da generišu ulazno-izlazna preslikavanja koja mogu da aproksimiraju bilo koju funkciju sa željenom tačnošću. Veštačke neuronske mreže se, u sistemima automatskog upravljanja, uglavnom koriste za *identifikaciju sistema* i *inteligentno upravljanje*.

Primena veštačkih neuronskih mreža ostvaruje se u diskretnom domenu. Simulacija rada nekog tehničkog sistema ne mora da se odvija u realnom vremenu. U tu svrhu se koriste približne, numeričke metode za rešavanje diferencijalnih jednačina, sa konstantnim ili promenljivim korakom integracije. U ovom radu, simulacija i eksperimenti su vršeni istovremeno, primenom *Simulink*-a i posebnog softvera QUARC za rad i upravljanje u realnom vremenu. S obzirom na brzinu prelaznog procesa, izabrana je perioda obabiranja od 0.002s što je ujedno bila i vrednost konstantnog koraka integracije u postupku simulacije.

Na osnovu diferencijalne jednačine ponašanja, ostavljajući sa leve strane samo izvod izlazne veličine:

$$\dot{x}_i(t) = \frac{A_m}{J_{eq}} x_u(t) - \frac{B_{eq}}{J_{eq}} x_i(t) \quad (20)$$

i usvajajući $x_i = y_p$, $x_u = u$ zbog kompatibilnosti označavanja datih veličina u literaturi [2], moguće je dobiti neophodnu diferencnu jednačinu:

$$\frac{y_p(k+1) - y_p(k)}{T} = \frac{A_m}{J_{eq}} u(k) - \frac{B_{eq}}{J_{eq}} y_p(k), \quad (21)$$

$$y_p(k+1) = \frac{A_m}{J_{eq}} T u(k) - \left(\frac{B_{eq}}{J_{eq}} T - 1 \right) y_p(k), \quad (22)$$

$$y_p(k+1) = f[y_p(k), u(k)]. \quad (23)$$

5.1 Primena veštačkih neuronskih mreža u identifikaciji sistema

Identifikacija sistema je analitička procedura za određivanje matematičkog modela sistema na osnovu izmerenih ulazno-izlaznih veličina. To znači da identifikacija sistema zahteva određenu analizu sistema, određivanje reda sistema, određivanje parametara i njihovo ocenjivanje. Generalno, dinamički sistem može biti opisan skupom diferencijalnih ili diferencnih jednačina. Na primer, višestruko prenosni sistem sa r ulaza i m izlaza može biti opisan preko:

$$\mathbf{x}(k+1) = \mathbf{f}(\mathbf{x}(k), \mathbf{u}(k)) \quad (24)$$

$$\mathbf{y}(k) = \mathbf{g}(\mathbf{x}(k)) \quad (25)$$


gde su $\mathbf{x}(k) \in \mathcal{R}^n$, $\mathbf{u}(k) \in \mathcal{R}^r$ i $\mathbf{y}(k) \in \mathcal{R}^m$ vektor stanja, ulaza i izlaza, sledstveno. Preslikavanja $\mathbf{f}: \mathcal{R}^r \times \mathcal{R}^n \rightarrow \mathcal{R}^n$ i $\mathbf{g}: \mathcal{R}^n \rightarrow \mathcal{R}^m$ su statička nelinearna preslikavanja. Modeli sistema se posmatraju u diskretnom domenu, kao i mreže.

Identifikacija sistema je neophodna kada funkcije $\mathbf{f}(\cdot)$ i $\mathbf{g}(\cdot)$ nisu poznate, pa ih je neophodno spoznati. Problem identifikacije sistema se tada transformiše u postupak određivanja pogodnog modela sistema, na osnovu ulazno-izlaznih veličina, tako da razlika izlaza sistema i modela za isti ulaz, bude manja ili jednaka nekoj unapred postavljenoj granici.

Identifikacija sistema podrazumeva izbor odgovarajućeg parametarskog modela i podešavanje parametara tog modela primenom nekog adaptivnog zakona, tako da odziv modela na određeni ulazni signal može da aproksimira ponašanje realnog sistema. Kako višeslojne neuronske mreže imaju veoma dobre mogućnosti aproksimacije, one predstavljaju moćan alat za identifikaciju nepoznatih sistema koji u sebi sadrže razne nelinearnosti. Nelinearna funkcija objekta se zamenjuje neuronskom mrežom sa fiksnim, ali nepoznatim matricama težinskih odnosa, a koja se obučava koristeći pogodan algoritam učenja na dostupnom skupu podataka. U procesu identifikacije sistema, razvija se arhitektura neuronske mreže i predstavlja model objekta koji treba upravljati. Identifikator se sastoji od višeslojne neuronske mreže koja je u paralelnoj vezi sa dinamičkim sistemom, a adekvatnost strukture se prati na osnovu standardne funkcije greške koja se koristi u teoriji upravljanja i identifikacije sistema [1, 2, 3]. Informacija o strukturi konfigurisane veštačke neuronske mreže, sadržana je u njenim vezama i težinskim odnosima [2, 5]. U ovom radu je korišćena identifikacija inverznog modela. Veštačka neuronska mreža se inače može obučavati *off-line*, u tzv. *batch* modu, i to koristeći najčešće zastupljen BP algoritam učenja. Jednom kada se veštačka neuronska mreža obuča da predstavlja inverzni model objekta, ona se tako konfigurisana i obučena, može koristiti za direktno upravljanje objekta, što će biti prikazano u nastavku rada.

5.2 Primena veštačkih neuronskih mreža u upravljačke svrhe

Najčešće korišćene upravljačke strukture, za primenu veštačkih neuronskih mreža u upravljanju, su one koje se koriste u adaptivnim sistemima upravljanja. Naime, neuronska mreža se koristi za ocenjivanje nepoznatog nelinearnog sistema, a nakon toga se sintetiše upravljanje korišćenjem prethodno obučene mreže. Postoji nekoliko osnovnih šema, odnosno postupaka, zasnovanih na veštačkim neuronskim mrežama, koje se koriste u upravljačke svrhe (direktno, indirektno, direktno inverzno, adaptivno upravljanje, itd.). Za potrebe ovog rada, na servo motoru jednosmerne struje, primenjena je jedna od najzastupljenijih šema neuro-upravljanja, zasnovana na direktno inverznom modelu. Ova šema koristi inverzni model upravljaniog sistema, koji je kaskadno povezan sa upravljanim objektom, da bi kompletan sistem rezultovao jediničnim preslikavanjem između željenog ponašanja (ulaz u neuronsku mrežu) i izlaza upravljaniog objekta. Zato ova neuronska mreža deluje direktno kao kontroler u glavnoj grani, a očekivani izlaz iz upravljaniog objekta jednak je željenom izlazu, što je ujedno konačni cilj preslikavanja, odnosno mašinskog učenja tokom inteligentnog upravljanja. Prvo se formira inverzni model objekta u cilju ocene izlaza inverznog modela $\hat{\mathbf{u}}$, slika 6 (levo). Takav izlaz $\hat{\mathbf{u}}$ se upoređuje sa signalom obučavanja \mathbf{u} i greška $\mathbf{e} = \mathbf{u} - \hat{\mathbf{u}}$ se koristi za obučavanje inverznog modela. Kada se dobije inverzni model, on se tada kaskadno vezuje sa objektom, i to kao kontroler u otvorenom kolu. Parametri neuro-kontrolera se podešavaju direktno. Direktno inverzno upravljanje je prikazano na slici 6 (desno). Referentni signal (željena vrednost izlaza) \mathbf{y}_d treba da pokriva dovoljno široku ulazno-izlaznu oblast tokom određivanja inverznog modela.



Slika 6. Blok dijagram direktno inverznog upravljanja: dobijanje inverznog modela (levo) i upravljanje u otvorenom kolu (desno) [2]

5.3 Modeli za identifikaciju i upravljanje

Modeli za identifikaciju i upravljanje nepoznatog nelinearnog dinamičkog sistema mogu se primeniti u analizi i sintezi takvih sistema koji sadrže neuronske mreže kao svoje podsisteme. U problemu identifikacije sistema koriste se četiri vrste diskretnog modela jednostruko prenosnog sistema [2]. Ovi modeli su izabrani zbog uopštenosti, ali i zbog postojećih, odgovarajućih modela koji se koriste u adaptivnim sistemima za identifikaciju linearnih sistema, a mogu se posmatrati i kao generalizacija za nelinearne sisteme. Pomenuti modeli se mogu opisati sledećim nelinearnim diferencnim jednačinama:

$$\text{Model I:} \quad y_p(k+1) = \sum_{i=0}^{n-1} a_i y_p(k-i) + g[u(k), \dots, u(k-m+1)], \quad m \leq n \quad (26)$$

$$\text{Model II:} \quad y_p(k+1) = f[y_p(k), \dots, y_p(k-n+1)] + \sum_{i=0}^{m-1} \beta_i u(k-i), \quad m \leq n \quad (27)$$

$$\text{Model III:} \quad y_p(k+1) = f[y_p(k), \dots, y_p(k-n+1)] + g[u(k), \dots, u(k-m+1)], \quad m \leq n \quad (28)$$

$$\text{Model IV:} \quad y_p(k+1) = f[y_p(k), \dots, y_p(k-n+1); u(k), \dots, u(k-m+1)], \quad m \leq n \quad (29)$$

gde $[y_p(k), u(k)]$ predstavlja ulazno-izlazni par objekta u trenutku k , a $f: \mathcal{R}^n \rightarrow \mathcal{R}$ i $g: \mathcal{R}^m \rightarrow \mathcal{R}$ su diferencijabilne funkcije svojih argumenata.

Da bi se identifikovao objekt, identifikacioni model se bira na osnovu *a priori* informacija koje odgovaraju klasi modela kome pripadaju. Na primer, ako se pretpostavi da model ima strukturu opisanu modelom III, cilj je tada odrediti težinske odnose dve neuronske mreže N^1 i N^2 , tako da preslikavanje N^1 bude jednako funkciji $g[\cdot]$, a preslikavanje N^2 jednako funkciji $f[\cdot]$. Ako su $y_p(k+1)$ i $\hat{y}_p(k+1)$, sledstveno, izlazi objekta i identifikacionog modela u trenutku $(k+1)$, greška $e(k+1) = y_p(k+1) - \hat{y}_p(k+1)$ se koristi za podešavanje težinskih odnosa neuronskih mreža N^1 i N^2 . Koristi se ili statički ili dinamički BP algoritam učenja, zavisno od strukture identifikatora. U tom smislu, mogu se razlikovati dva modela identifikatora (modela za testiranje rada obučenih veštačkih neuronskih mreža):

- **paralelni model** koristi izlaz identifikacionog modela (mreže), a može se opisati jednačinom:

$$\hat{y}_p(k+1) = N^2[\hat{y}_p(k), \dots, \hat{y}_p(k-n+1)] + N^1[u(k), \dots, u(k-m+1)]. \quad (30)$$

- **serijsko-paralelni model** zahteva da se koristi izlaz iz objekta, a opisan je jednačinom:

$$\hat{y}_p(k+1) = N^2[y_p(k), \dots, y_p(k-n+1)] + N^1[u(k), \dots, u(k-m+1)]. \quad (31)$$

6. EKSPERIMENTALNA VERIFIKACIJA

6.1 Simulacija i eksperimentalna verifikacija dobijenog modela objekta

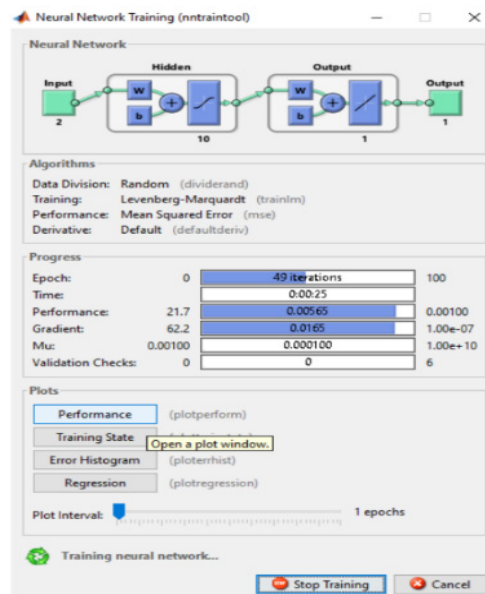
Eksperimenti su vršeni primenom *Simulink*-a [11], zadavanjem različitih ulaznih signala poput *chirp*, *random*, *repeating sequence*, *step* i sinusnog signala, i to po nekoliko puta, sa različitim parametrima. Na osnovu sačuvanih podataka (vrednosti zadatih ulaza i odziva motora) izvršeno je obučavanje neuronske mreže u MATLAB-u [11], pomoću odgovarajućeg koda u kojem se, zadavanjem potrebnih komandi, mreža obučava, a naravno, prethodno se određuje: broj skrivenih slojeva, dozvoljena greška, maksimalan broj iteracija, itd.

Na slici 7, prikazan je proces obučavanja troslojne veštačke neuronske mreže kao i njena struktura, gde se vidi da obučavana mreža sadrži jedan skriveni sloj u kojem se nalazi deset neurona i izlazni sloj sa jednim

neuronom. Takvoj strukturi veštačke neuronske mreže prethodi postupak podešavanja broja neurona u skrivenom sloju, počevši od manjeg, sve dok mreža nije pokazala zadovoljavajuće rezultate na obučavajućem skupu podataka.

Odabirom vrednosti greške koja se zadaje na početku, uz nameru da mreža bude dovoljno tačno obučena kako bi kasnije zadovoljila neophodna testiranja, jer u suprotnom slučaju, ona može dati grešku jednaku nuli na obučavajućem skupu podataka, dok pri testiranju može pokazati veoma nezadovoljavajuće rezultate. Tada se konstatuje da je došlo do preobučavanja neuronske mreže.

Nakon adekvatnog obučavanja neuronske mreže, neophodno je testirati datu mrežu korišćenjem više različitih eksperimentalno prikupljenih signala, kako bi se izveo zaključak da li je neophodno njeno ponovno obučavanje radi dobijanja zadovoljavajućih rezultata ili je u datom trenutku mreža već validno obučena. Eksperimentalni rezultati obučених veštačkih neuronskih mreža, za model II i model IV, kao i testiranja na paralelnim i serijsko-paralelnim modelima, biće prikazani u nastavku ovog rada.



Slika 7. Neural Network Train Tool-prikaz

Testiranje na paralelnim modelima

Paralelni model podrazumeva testiranje rada obučene neuronske mreže na osnovu ulaznog signala i izlaza iz mreže, u datom trenutku, što je moguće zaključiti iz jednačine:

$$\hat{y}_p(k+1) = f[\hat{y}_p(k), u(k)]. \quad (32)$$

Mreže obučene na osnovu odziva DC servo motora za *chirp* signal, testirane su za više različitih ulaznih signala, a rezultati obučene mreže za model II prikazani su na slici 12, dok su za model IV dati na slici 17.

Testiranje na serijsko-paralelnim modelima

Karakteristika serijsko-paralelnog modela ogleda se u tome da se odziv sistema u trenutku $(k+1)$ dobija na osnovu odziva stvarnog objekta u trenutku k i ulaza u tom trenutku:

$$\hat{y}_p(k+1) = f[y_p(k), u(k)]. \quad (33)$$

Date obučene neuronske mreže (na osnovu odziva servo motora jednosmerne struje za *chirp* i *random* signale), testirane su za nekoliko različitih ulaznih signala, a eksperimentalni rezultati obučених mreža za model II prikazani su na slikama 10 i 11, dok su za model IV dati na slikama 15 i 16.

6.1.1 Prvi metod identifikacije

Prvo je razmatran identifikacioni model II, predstavljen jednačinom (27), u opštem obliku. Diferencijalna jednačina ponašanja (18), naglašava se da je data sa oznakama korišćenim kada su u pitanju veštačke neuronske mreže, i to u vremenskom domenu, sledećeg je oblika:

$$J_{eq}\dot{y}_p(t) + N(y_p(t)) = A_m u(t). \quad (34)$$

U diskretnom domenu, diferencna jednačina je tada:


$$y_p(k+1) = N(y_p(k)) + \frac{A_m}{J_{eq}} T u(k). \quad (35)$$

Za korišćeni DC servo motor, jednačina identifikacionog modela II (27) postaje:

$$y_p(k+1) = f[y_p(k)] + \frac{A_m}{J_{eq}} T u(k), \quad (36)$$

$$f[y_p(k)] = y_p(k+1) - \frac{A_m}{J_{eq}} T u(k). \quad (37)$$


Opravdanost uvođenja neuronskih mreža ogleda se u mogućnosti mreže da identifikuje nelinearnost, kada linearni matematički model ne opisuje dobro rad objekta, kao što je pokazano da važi u slučaju servo motora jednosmerne struje Quanser SRV02 [8], a postupak identifikacije je opisan jednačinom (37) i prikazan je strukturnim dijagramom na slici 8.



Slika 8. Dijagram modela II

Dakle, ulaz u neuronsku mrežu biće vrednost izlaza u datom trenutku, dok je izlaz iz mreže razlika vrednosti izlaza u sledećem trenutku i ulaza u k -tom trenutku. Naime, neuronske mreže su obučene pomoću snimljenih


odziva motora za zadate *chirp* i *random* ulazne signale. *Chirp* obučavajući signal je konstantne amplitude 4, dok je frekvencija promenljiva u zadatom opsegu od 0.02Hz do 2Hz. *Random* signal je ograničen najvećom mogućom razlikom između vrednosti signala u dve susedne periode (zadata perioda je 250s, a pomenuta razlika 10). Eksperimentalni rezultati obučene mreže, za pomenuta dva signala, prikazani su na slici 9.



Slika 9. Poređenje odziva DC servo motora (plavo) i obučene neuronske mreže (crveno) za chirp signal (levo) i random signal (desno)


Rezultati testiranja rada obučene mreže na serijsko-paralelnim modelima

• Mreža obučena na chirp signalu:




Slika 10. Poređenje odziva DC servo motora (plavo) i obučene neuronske mreže (crveno) za odskočni, sinusni, repeating sequence, chirp i random ulaz, sledstveno

• Mreža obučena na random signalu:



Slika 11. Poređenje odziva DC servo motora (plavo) i obučene neuronske mreže (crveno) za odskočni, sinusni, repeating sequence, chirp i random ulaz, sledstveno

Rezultati testiranja rada obučene mreže (za chirp signal) na paralelnim modelima



Slika 12. Poređenje odziva DC servo motora (plavo) i obučene neuronske mreže (crveno) za odskočni ulaz i sinusne ulaze različitih amplituda i frekvencija, sledstveno

6.1.2 Drugi metod identifikacije


Sledeći identifikacioni model, korišćen za obučavanje neuronskih mreža je model IV, predstavljen jednačinom (29), u opštem slučaju. Diferencna jednačina data je kao:

$$y_p(k+1) = N(y_p(k)) + \frac{A_m}{J_{eq}} T u(k). \quad (38)$$

Razlika između prethodno razmatranog modela za identifikaciju i trenutnog, ogleda se u mogućnosti predstavljanja modela i na sledeći način:


$$y_p(k+1) = f[y_p(k), u(k)]. \quad (39)$$

Neuronska mreža obučavana je pomoću dva skupa obučavajućih podataka, vrednosti ulaznog signala i vrednosti izlaza iz mreže u datom trenutku, dok je izlaz dat za sledeći trenutak. Naravno, neophodno je pri obučavanju usvojiti početne vrednosti ulaza i izlaza. Strukturni dijagram modela IV, prikazan je na slici 13.



Slika 13. Dijagram modela IV


Neuronske mreže su obučene na osnovu snimljenih odziva DC servo motora za zadate *chirp* i *random* ulazne signale. *Chirp* obučavajući signal je konstantne amplitude 2, dok je frekvencija promenljiva u zadanom opsegu od 0.01Hz do 1Hz. *Random* signal je ograničen najvećom mogućom razlikom između vrednosti signala u dve susedne periode (zadata perioda je 250s, a pomenuta razlika 10). Eksperimentalni rezultati obučениh neuronskih mreža, za pomenuta dva signala, prikazani su na slici 14.



Slika 14. Poređenje odziva DC servo motora (plavo) i obučene neuronske mreže (crveno) za chirp signal (levo) i random signal (desno)


Rezultati testiranja rada obučениh mreža na serijsko-paralelnim modelima

- Mreža obučena na *chirp* signalu:




Slika 15. Poređenje odziva DC servo motora (plavo) i obučene neuronske mreže (crveno) za odskočni, sinusni, repeating sequence i random ulaz, sledstveno

- Mreža obučena na *random* signalu:



Slika 16. Poređenje odziva DC servo motora (plavo) i obučene neuronske mreže (crveno) za odskočni, sinusni, repeating sequence i random ulaz, sledstveno


Rezultati testiranja rada obučene mreže (za *chirp* signal) na paralelnim modelima




Slika 17. Poređenje odziva DC servo motora (plavo) i obučene neuronske mreže (crveno) za odskočni ulaz i sinusne ulaze različitih amplituda i frekvencija, sledstveno

6.2 Realizacija inteligentnog upravljanja i poređenje simulacionih i eksperimentalnih rezultata

Realizovano je direktno inverzno upravljanje koje je ranije objašnjeno. Pre svega snimljene su vrednosti *chirp* signala, kao i odziva za zadati signal, konstantne amplitude 2 i promenljive frekvencije čija se učestanost vremenom povećava na zadatom opsegu od 0.01Hz do 1Hz. Za dati signal dobijen je inverzni model. Tada je neuronska mreža obučavana na osnovu dva ulaza, i to: vrednosti izlaza objekta u datom trenutku i vrednosti izlaza u prethodnom trenutku, dok je izlaz iz obučene mreže zapravo upravljanje za dati sistem. Prikaz strukturnog dijagrama inverznog modela, dat je na slici 18. Nakon obučavanja mreže i testiranja, moguće je realizovati inteligentno upravljanje objekta pomoću neuronskih mreža. Naime, zadovoljavajuće obučenu mrežu je neophodno generisati u *Simulink* blok čiji su ulazi, željena vrednost izlaza i stvarni izlaz objekta očitani sa tahometra, dok je izlaz iz mreže upravljanje za dati objekt. Blok šema upravljanja, prikazana je na slici 19.

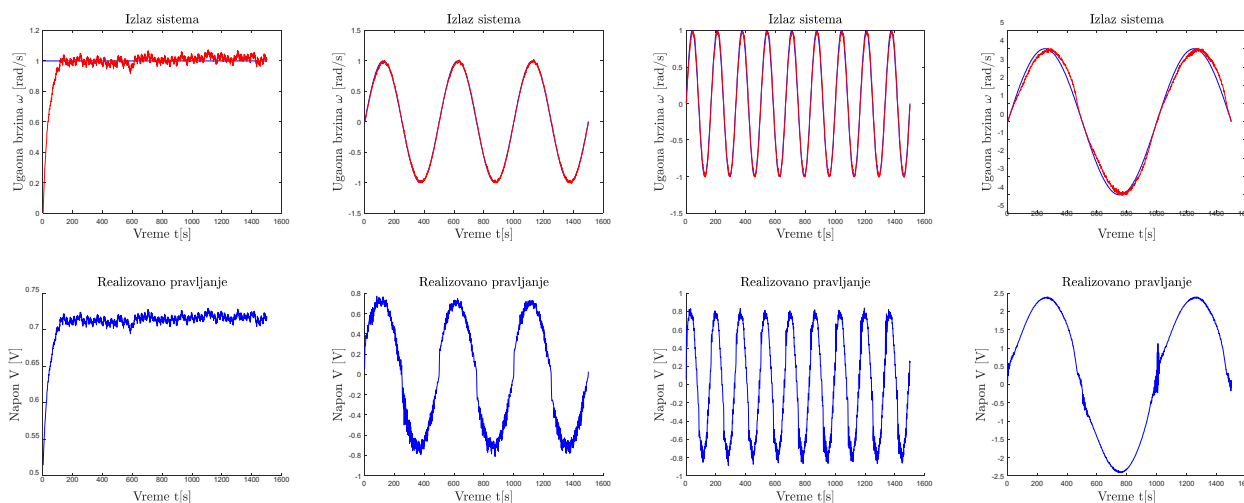


Slika 18. Dijagram inverznog modela



Slika 19. Simulink model sistema

Realizovano inteligentno upravljanje, kao izlaz iz veštačke neuronske mreže, kao i poređenje simulacionih sa eksperimentalnim rezultatima, i to za različite testirane signale, prikazano je konačno na slici 20.



Slika 20. Poređenje odziva (crveno) i željene vrednosti izlaza (plavo) sistema DC servo motora (gore) i promena upravljanja (dole) za jediničnu odskočnu željenu vrednost i sinusne signale različitih amplituda i frekvencija, sledstveno

7. ZAKLJUČAK

Rad je imao za cilj modelovanje i inteligentno upravljanje servo motora jednosmerne struje primenom veštačkih neuronskih mreža, što je realizovano kroz simulaciju i eksperimentalnu verifikaciju. Od razmatranih modela, ocenjivan je paralelni model kao i serijsko-paralelni model. Sproveden je niz eksperimenata koji su pomogli u donošenju validnih zaključaka, posle obučavanja veštačkih neuronskih mreža, i to u domenu identifikacije izlaza objekta.

Na osnovu brojnih eksperimenata, realizovanih kod paralelnog modela, može da se zaključi da je neuronska mreža, obučavana na osnovu snimljenih veličina stanja (npr. ulazni *chirp* signal i odziv motora), odgovarajuća za pojedine jednostavnije tipove signala.

Posmatrajući realizovane eksperimente, ostvarene kod serijsko-paralelnog modela, može da se izvede zaključak da su veštačke neuronske mreže, obučavane na osnovu snimljenih veličina stanja (ulaznih *chirp* i *random* signala i odziva motora), odgovarajuće za sve signale na kojima je vršeno testiranje mreže. Takođe, može da se primeti da su poklapanja kod serijsko-paralelnog modela, u odnosu na paralelni, višeg nivoa tačnosti, zbog toga što se kod paralelnog modela za testiranje uzima vrednost izlaza neuronske mreže u prethodnom trenutku, tako da je očekivano da se greška vremenom povećava.

Na kraju, posmatranjem svih ostvarenih eksperimentalnih rezultata, može da se zaključi da je inteligentno upravljanje predmetnog objekta - DC servo motora, bazirano na primeni obučanih veštačkih neuronskih mreža, ostvareno sa zadovoljavajućom tačnošću, i to kod oba razmatrana modela za identifikaciju i upravljanje.

Posmatrajući sve navedene zaključke, a posebno eksperimentalne rezultate prikazane u poglavlju 6, opravdanost uvođenja inteligentnih sistema upravljanja, kod ispitivanog objekta kao što je servo motor jednosmerne struje, apsolutno je evidentna. Uspešna primena inteligentnog sistema upravljanja baziranog na korišćenju veštačkih neuronskih mreža, ovde verifikovana na servo motoru jednosmerne struje, otvara mogućnost realizacije sličnih modernih sistema upravljanja i kod složenijih objekata, kao što su svi oni koji koriste ovaj tip motora, što je i očekivana smernica budućeg naučno-istraživačkog rada, posebno u domenu razvoja dinamičke optimizacije inteligentnih robotskih sistema u okviru Industrije 4.0, u svetu i kod nas.

8. LITERATURA

- [1] Radiša Jovanović, *Matlab i Simulink u automatskom upravljanju*, Mašinski fakultet u Beogradu, 2016.
- [2] Radiša Jovanović, *Predavanja iz predmeta Inteligentni sistemi upravljanja - pisani materijali*, Mašinski fakultet u Beogradu, 2017.
- [3] Radiša Jovanović, *Predavanja iz predmeta Osnove automatskog upravljanja - pisani materijali*, Mašinski fakultet u Beogradu, 2016.
- [4] Katarina Miljković, *Modelovanje i upravljanje servo motora jednosmerne struje primenom neuronskih mreža*, Master rad, Mašinski fakultet u Beogradu, 2018.
- [5] Zoran Miljković i dr., *Veštačke neuronske mreže – zbirka rešenih zadataka sa izvodima iz teorije*, Mašinski fakultet u Beogradu, II izdanje, 2018.
- [6] Simon Haykin, *Neural Networks: A Comprehensive Foundation*, 3rd Edition, May 2007, Prentice-Hall, Inc, USA.
- [7] User Manual – SRV02 Rotary Servo Base Unit
- [8] Student Workbook – SRV02 Base Unit
- [9] User Manual – Q8-USB Data Acquisition Device
- [10] User Manual – VoltPAQ-X1 Amplifier
- [11] MATLAB and *Simulink*. (2016). Natick, Massachusetts United States.: The MathWorks Inc.

Miljković, K., Petrović, M.M., Jovanović, R.

TOWARDS DEVELOPMENT OF DC SERVO MOTOR INTELLIGENT CONTROL BY APPLYING ARTIFICIAL NEURAL NETWORKS

Abstract: *In this paper the possible approach of DC servo motor intelligent control is presented by using artificial neural networks. Besides the application of one of the most important techniques of artificial intelligence, this paper suggests and gives the mathematical modelling of widely used object of automatic control. Also, this paper uses abilities of artificial neural networks in order to generalize and approximate the outputs of this object by applying machine learning through the process of its training, aiming to overcome the faults connected to the conventional control of the DC servo motor. The suggested approach, was analyzed firstly by simulation, and then it was experimentally verified in two out of four models which were taken into consideration.*

Key words: *intelligent control, DC servo motor, artificial neural networks, machine learning, mathematical modelling*