

DOI: [10.46793/CIGRE37.C4.11](https://doi.org/10.46793/CIGRE37.C4.11)

## C4.11

**PRIMENA NEURALNIH MREŽA ZA ESTIMACIJU NEMERLJIVIH PARAMETARA U  
INDUSTRIJSKIM PROCESIMA****APPLICATION OF NEURAL NETWORKS FOR ESTIMATING UNMEASURABLE  
PARAMETERS IN INDUSTRIAL PROCESSES****Balša Čeranić, Slobodan Vukojičić, Marija Novičić, Goran Kvašček, Leposava Ristić\***

**Kratak sadržaj:** Poslednjih godina, mašinsko učenje se pokazalo kao put do rešenja mnogih zadataka inženjera i naučnika koji se bave temama iz oblasti kao što su: obrada signala, slike, videa, prirodnog jezika, prepoznavanje objekata i anomalija, predviđanja raznih događaja od važnosti i svih ostalih oblasti, jer je evidentno da je mašinsko učenje našlo sebi prostora u svim facetima ljudske delatnosti. Suvišno je isticati da je potencijal mašinskog učenja u industrijskim procesima enorman. Kako se u industriji stalno teži unapređenju efikasnosti i ekonomičnosti procesa, kao i kvalitetu konačnog proizvoda, standardne strategije upravljanja sve teže ispunjavaju rastuće uslove koje postavljaju proizvođači, ali i potrošači. Razvijanje naprednih strategija nadzora i upravljanja je od vitalnog značaja za sve grane privrede. Ovakve strategije se najčešće oslanjaju na poznavanje parametara uređaja i materijala kojima se barata. Parametri u procesu se mogu podeliti na one koji su jednostavni i pristupačni za merenje, kao što su brzine, naponi i struje, i one za čije merenje je potrebno integrisati u sistem složene i skupe merne uređaje, što u nekim primenama nije opravdano (unutrašnje deformacije i karakteristike obrađivanih materijala). Cilj ovog rada je ispitivanje mogućnosti neuralnih mreža u određivanju nemerljivih mehaničkih parametara u industrijskom elektromotornom pogonu koji prema svojim performansama predstavlja mehanički rezonantni sistem, a na osnovu merenja dostupnih u procesu. Opisani postupak teži formiranju neuralne mreže koja na osnovu merenja brzine pogonske mašine određuje koeficijente viskoznosti i elastičnosti mehaničke veze (vratila) i momenta inercije opterećenja, koji figurišu u modelu dve mase, i neophodni su za potrebe prediktivnog upravljanja. Razvijene su i testirane različite arhitekture neuralnih mreža: višeslojni perceptron, konvolucione neuralne mreže i rekurentne neuralne mreže. Performanse su dodatno unapređene korišćenjem različitih načina pribavljanja podataka za treniranje, a rezultati primene su prikazani u radu.

**Ključne reči:** *Neuralne mreže, Mašinsko učenje, Industrijski procesi, Estimacija parametara, Elektromotorni pogoni*

---

\* Balša Čeranić, Elektrotehnički fakultet u Beogradu, [ceranic@etf.bg.ac.rs](mailto:ceranic@etf.bg.ac.rs)  
Slobodan Vukojičić, Elektrotehnički fakultet u Beogradu, [danevukojiacic@gmail.com](mailto:danevukojiacic@gmail.com)  
Marija Novčić, Elektrotehnički fakultet u Beogradu, [novicic@etf.bg.ac.rs](mailto:novicic@etf.bg.ac.rs)  
Goran Kvašček, Elektrotehnički fakultet u Beogradu, [kvascev@etf.bg.ac.rs](mailto:kvascev@etf.bg.ac.rs)  
Leposava Ristić, Elektrotehnički fakultet u Beogradu, [lela@etf.bg.ac.rs](mailto:lela@etf.bg.ac.rs)

**Abstract:** In recent years, machine learning has proven to be a solution for many engineering and scientific challenges across a wide range of fields. It has applications in all facets of human activity, and its potential in industrial processes has become evident. Since industry continuously strives to improve process efficiency, cost-effectiveness, and product quality, conventional control strategies are increasingly struggling to meet the growing demands of both manufacturers and consumers. Developing advanced monitoring and control strategies is of vital importance for all branches of industry. Such strategies often rely on knowledge of the parameters of the devices and materials involved in the process. Some parameters are easily measurable, such as speeds, voltages, and currents, while others require complex measurement equipment, use of which may not be justified in certain applications. The aim of this paper is to investigate the capability of neural networks in estimating unmeasurable mechanical parameters in an industrial electric drive system, using available measurements. The approach aims to develop a neural network that, using measurements of the drive machine's speed, estimates viscosity and stiffness coefficients of the shaft and load inertia, which can vary over time in an industrial process. These mechanical parameters are part of two-mass model used to describe the mechanical resonant system and are essential for predictive control. Various neural network architectures have been developed and tested, including: multilayer perceptron, convolutional neural network, and recurrent neural network. Performance was further improved by employing different data acquisition techniques for training, and the results of the proposed approach are presented in the paper.

**Key words:** *Neural networks, Machine learning, Industrial processes, Parameter estimation, Electrical drives*

## 1 UVOD

Veštačka inteligencija danas nalazi primenu u svim aspektima ljudske delatnosti, posebno u slučajevima gde se pred čovekom nalazi zadatak koji zahteva brzu obradu velike količine podataka i prepoznavanje suptilnih obrazaca u svrhu donošenja pravovremenih i ispravnih odluka. Veštačka inteligencija, dakle, nije sposobna da zameni ljudsku, već je dopunjuje svojim mogućnostima u rešavanju obimnih i složenih zadataka. Takvi zadaci su često neizbežni u sprovođenju raznovrsnih rešenja, koja i dalje pretežno proističu iz ljudskog kreativnog i intuitivnog razmišljanja.

U cilju implementacije složenih algoritama upravljanja elektromotornim pogonima, koji se zasnivaju na preciznom poznavanju industrijskog procesa i sistema kojim se upravlja, testirane su sposobnosti neuralnih mreža da estimiraju parametre sistema koji su inače teško merljivi. To se odnosi pre svega na svojstva materijala kroz koji se prenosi mehanička energija u industrijskim procesima, odnosno na mehaničke parametre vratila koje povezuje pogonsku mašinu sa procesom, tj. opterećenjem. Takođe se odnosi i na osobine opterećenja, koje se sa strane motora vidi kao moment inercije.

Rad je organizovan tako da je u narednom poglavlju predstavljena motivacija i značaj rada. U trećem poglavlju su detaljnije opisane arhitekture neuralnih mreža koje su testirane za ovu primenu. U četvrtom su izloženi i upoređeni rezultati koje su različite arhitekture ostvarile. U zaključnom poglavlju su izvedene pouke i predstavljeni dalji planovi razvijanja i produbljivanja teme ovog rada.

## 2 MOTIVACIJA I ZNAČAJ RADA


Pri upravljanju i nadzoru elektromotornog pogona koji pokreće složen industrijski proces, samo upravljanje i nadzor takođe inherentno imaju određenu složenost. Složeni algoritmi upravljanja se, po pravilu, oslanjaju na poznavanje brojnih parametara procesa kojim se upravlja, u posmatranom slučaju elektromotornog pogona. Elektromotorni pogon je u ovom radu predstavljen kao oscilatorni sistem dve mase, koje predstavljaju pogonsku mašinu i opterećenje, mehanički spregnute vratilom koje ima konačne, nezanemarljive vrednosti koeficijenata krutosti (elastičnosti) i viskoznosti. Sistem dve mase je opisan jednačinama (1) – (4) i prikazan na slici 2.1.

$$J_m \frac{d\omega_m}{dt} = M_m - M_o \quad (1)$$

$$J_l \frac{d\omega_l}{dt} = M_o - M_l \quad (2)$$

$$\frac{d\theta_m}{dt} = \omega_m, \frac{d\theta_l}{dt} = \omega_l \quad (3)$$

$$M_o = K_k(\theta_m - \theta_l) + K_v(\omega_m - \omega_l) \quad (4)$$



Slika 2.1: Mehanički oscilatorni sistem dve mase spregnute vratilom konačne krutosti i viskoznosti

$J_m$  i  $J_l$  označavaju moment inercije motora i moment inercije opterećenja respektivno,  $M_m$  je moment kojim motor deluje na vratilo,  $M_l$  je moment kojim opterećenje deluje na vratilo, dok je  $M_o$  torzioni moment kojim vratilo deluje na motor i na opterećenje. Ovaj moment se smatra jednakim na oba kraja vratila zbog aproksimacije da se vratilo jednako deformiše u svakom svom delu. Torzioni moment zavisi od ugla za koji su međusobno smaknuti krajevi vratila  $\theta_m - \theta_l$ , razlike brzina motora i opterećenja  $\omega_m - \omega_l$ , kao i koeficijenata krutosti  $K_k$  i viskoznosti  $K_v$  [1].

Za ovakav sistem se kao povoljno rešenje nudi prediktivni regulator zbog svoje pouzdanosti pri regulaciji brzine i momenta pogona. Ovakav regulator višestruko smanjuje mehaničke oscilacije koje su posledica konačne elastičnosti vratila koje povezuje pogonsku mašinu i industrijski proces. Ove oscilacije se ogledaju u značajnim fluktuacijama momenta tokom prelaznih stanja, što može dovesti do naprezanja mehaničkog podsistema i ubrzanog zamora materijala. Prediktivni regulator u velikoj meri smanjuje torzione oscilacije, uz preduslov poznavanja svih parametara mehaničkog sistema [2].


Od svih parametara koji figurišu u ovakvom modelu pogona, smatra se da je poznat i nepromenljiv moment inercije motora, koji se dobija kao kataloški podatak. Moment inercije opterećenja može da se menja u širokom opsegu, zbog promene u procesu ili proizvodu. Na primer, moment inercije robotske ruke zavisi od mase predmeta koji nosi i od rastojanja tog predmeta od ose rotacije, koje takođe može da se menja. U pogonima premotača se moment inercije opterećenja menja kontinualno, kako se proizvod namotava na rolnu, što pomera centar mase i menja moment inercije. Koeficijent viskoznosti u najvećoj meri zavisi od stanja ležajeva, i ako se uspostavi dobar sistem za estimaciju njegove vrednosti, osim uloge u naprednim metodama upravljanja, može da služi i svrsi održavanja pogona, tako da se zna u kom trenutku je potrebno podmazati ležajeve. Koeficijent elastičnosti je karakteristika vratila i pruža informaciju o njegovom stanju. U promenama koeficijenta elastičnosti se mogu registrovati nevidljiva unutrašnja oštećenja vratila, sa kojima bi pogon mogao da nastavi sa radom uz preporuku za pregledanje ili popravku vratila pri sledećoj pauzi u proizvodnji. Jednom kada oštećenja postanu vidljiva, najčešće se trenutno zaustavlja proizvodnja, što dovodi do finansijskog gubitka. Dakle, i koeficijent elastičnosti ima dvojaku ulogu, osim što figuriše u naprednom upravljanju, poznavanje njegovih promena omogućava i ekonomičnije održavanje pogona.

Promena parametara jednog ovakvog sistema utiče na njegov odziv na poremećaj. Postupak za estimaciju parametara zasnovan je na injektiranju poremećaja u sistem i analizi odziva koji nastaje kao njegova posledica. U ovom slučaju je kao poremećaj iskorišćen pogonski moment elektromotora, čija se zadata vrednost, u trenutku u kom proces to dozvoljava, poveća tek toliko da proizvede promenu brzine koja se može analizirati, a koja ne utiče na sam industrijski proces. Predviđeno je da se brzina meri pomoću enkodera na strani motora i da se dobijeno merenje ubrzanja na strani motora prosledi na ulaz neuralne mreže. Koristi se 1000 odbiraka ubrzanja kojima prethodi kratkotrajna promena referentnog momenta motora. Na izlazu iz neuralne mreže se dobijaju estimirane vrednosti momenta inercije opterećenja, koeficijenta krutosti i koeficijenta viskoznosti mehaničke veze između momenta i opterećenja.

### **3 KORIŠĆENE ARHITEKTURE NEURALNIH MREŽA**

#### **3.1 Višeslojni perceptron**

Osnovni primer neuralne mreže je višeslojni perceptron (*Multilayer perceptron – MLP*). Ovaj tip neuralne mreže predstavlja složenu matematičku funkciju kojom se obrađuje skup ulaznih podataka, primenjujući na njih prostije funkcije, kao što su sabiranje i množenje konstantnom vrednošću. Ovakva struktura, prikazana na slici 3.1, sastoji se iz više slojeva potpuno povezanih neurona. Prvi sloj je ulazni sloj koji, u slučaju rada sa vremenskim serijama, ima onoliko neurona kolika je dužina sekvence koja se obrađuje. Sledeći sloj je prvi skriveni sloj, koji sadrži onoliko neurona koliko zahteva primena. Informacija u svakom neuronu prvog skrivenog sloja se izračunava tako što se svaka informacija iz prethodnog sloja (ulaznog) množi konstantom (težinskim faktorom) koji je jedinstveno određen za svaki par neurona iz susednih slojeva. Dobijeni proizvodi se sabiraju i na njihov zbir se dodaje konstanta (pomak) koja je takođe jedinstveno određena za svaki neuron u svim slojevima osim ulaznog. Iza prvog skrivenog sloja često postoji niz skrivenih slojeva, kroz koje se informacije prosleđuju isto kao sa ulaznog na prvi skriveni sloj. Svaki neuron je na slici 3.1 predstavljen krugom, svakoj vezi između dva neurona odgovara poseban težinski faktor, dok svakom neuronu koji nije u ulaznom sloju odgovara jedinstven pomak. Zbog toka podataka kroz ovakvu mrežu, u kojoj nema povratnih veza, već informacije teku samo u napred, ona se na engleskom jeziku najčešće naziva *feedforward neural network*.



Slika 3.1: Grafički prikaz višeslojne neuralne mreže

Ovakva neuralna mreža treba da obezbedi približnu aproksimaciju funkcije proizvoljnog broja argumenata koristeći se linearnim funkcijama množenja konstantom i sabiranja. U slučaju koji se razmatra u ovom radu, argumenata je, kao i broja odbiraka, 1000. Ostvarivanje željene aproksimacije zahteva veći broj neurona, i veći broj skrivenih slojeva, što znači da broj parametara koje treba podesiti kod ovakve neuralne mreže može biti prevelik da bi se taj proces brzo završio. U ovom radu je kao prioritet usvojena optimizacija vremena potrebnog za trening, zasnovana na osnovnoj arhitekturi neuralne mreže.

Treniranje neuralne mreže se odvija na skupu podataka koji je podeljen na više podskupova: jedan podskup se koristi za trening, drugi za validaciju, a treći je opcioni i koristi se za testiranje po završetku treniranja. Skup za validaciju donosi odluku o tome kada se trening završava. Treniranje se završava kada se rezultat funkcije greške spusti ispod željene vrednosti ili kada vrednost greške na skupu za validaciju počne da raste, što je znak da je mreža previše dobro naučila trening podatke i nije sposobna da na adekvatan način obradi podatke koji nisu u trening podskupu.

Višeslojni perceptron predstavlja osnovu za druge razmatrane arhitekture, koje su specijalni slučajevi ovog, opšteg tipa neuralne mreže. Rezultati ostvareni mrežama istreniranim na opisani način biće prikazani u narednom poglavlju.

### 3.2 Konvoluciona neuralna mreža

Konvoluciona neuralna mreža (*Convolutional Neural Network – CNN*) je specijalizovana za obradu podataka kao što su slike, koje predstavljaju dvodimenzionalnu matricu piksela, ili vremenskih nizova odbiraka nekog signala, koji imaju jednodimenzionalnu topologiju. Konvoluciona neuralna mreža na predmet obrade, bila to slika ili signal, primenjuje matematičku operaciju konvolucije. Konvolucija teži da u jednom odbirku obuhvati informacije koje su sadržane u više posebnih odbiraka originalne funkcije, pomoću druge funkcije koja učestvuje u operaciji i koja ima ulogu filtra. Zahvaljujući svojoj strukturi, najveću primenu je našla u oblasti prepoznavanja oblika.

Način na koji se u ovom tipu neuralne mreže obrađuju ulazni podaci, upravo odgovara traženju poznatih šablona ili oblika na skupu ulaznih podataka. Na matricu ulaza (zamislmo fotografiju koja se sastoji od piksela) se primenjuju filtri koji vrše konvoluciju, čiji će rezultat zavisiti od toga da li se na sekciji koja podleže konvoluciji prepozna određeni oblik (to može biti krug,

vertikalna ili horizontalna linija...). Oblik se može prepoznati ukoliko između filtra i sekcije slike koja mu podleže postoji poklapanje. U slučaju obrade sekvence odbiraka signala, primenjuje se *1D CNN* – jednodimenzionalna konvoluciona neuralna mreža. Kao što je već predstavljeno na primeru slike koja se sastoji od piksela, pomoću konvolucionih filtara se mogu prepoznati i talasni oblici nekog signala.

Kod konvolucionih neuralnih mreža je značajno i to što, za razliku od višeslojnih perceptrona, postoji nizak stepen povezanosti neurona. Kod konvolucionih mreža su ulaz i izlaz povezani upravo preko filtara, koji svojim delovanjem menjaju sliku dobijenu na ulazu u mrežu i prevode je u klasifikaciju ili regresiju koja se traži na izlazu. Broj parametara koji se treniraju ne zavisi od veličine ulaznih podataka, već od broja filtara i njihovih dimenzija. Ovaj broj bi idealno odgovarao broju različitih oblika koje mreža treba da nauči da prepozna. Za prepoznavanje manjih oblika na slici ili brzih promena u vremenskom nizu se koriste filtri manjih dimenzija, a za veće oblike i sporije procese, filtri većih dimenzija.

U svrhu veće robusnosti neuralne mreže i manjeg oslanjanja na pojedine neurone, ovde je primenjena metoda *dropout*, koja “gasi” određenu grupu neurona u svakoj iteraciji prolaska trening podataka kroz mrežu. Uvrštavanje *dropout* sloja ima i funkciju u sprečavanju pojave poznate kao *overfitting*. Do nje dolazi kada mreža izgubi sposobnost generalizacije, to jest kada ima velike greške obrade ulaznih podataka koji nisu korišćeni za trening. Kada mreža previše dobro nauči podatke koji su joj dati za trening, težinski faktori će uzeti veće vrednosti i davati veća odstupanja za manje promene ulaznih podataka. U sledećem poglavlju su upoređene i performanse konvolucione neuralne mreže sa i bez upotrebe *dropout* metode, kao i sa različitim dimenzijama filtara.

### 3.3 *LSTM* rekurentna neuralna mreža

Rekurentne neuralne mreže imaju najveću primenu u obradi sekvencijalnih podataka. Sekvencijalni podaci koji se ovde podrazumevaju mogu biti nizovi odbiraka signala, ali i nizovi reči u rečenici, kao i rečenica u tekstu. Rekurentne mreže se posebno često sreću u obradi jezika – prevodima i generisanju teksta. Njihova velika prednost je što mogu da rade sa dugačkim nizovima podataka. Ova osobina je postignuta deljenjem parametara (*parameter sharing*), gde se isti parametri primenjuju na različite delove ulaza. Takođe se postiže mogućnost obrade podataka nezavisno od dužine sekvence. Ovaj princip podseća na jednodimenzionalne konvolucione neuralne mreže, ali postoji razlika u tome što informacije u svakom izlazu zavise od svih prethodnih izlaza, umesto samo od susednih [3].


Jedna podvrsta rekurentne neuralne mreže je *LSTM* – *Long short-term memory*, čija struktura se oslanja na formiranje veze, ili petlje, jednog čvora sa samim sobom. Na taj način podaci iz ranijih trenutaka mogu dugo da ostanu u petlji, ako su dovoljno relevantni. O relevantnosti prethodnih podataka odlučuju „kapije“ (engl. *gates*) koje su sastavni delovi jedne LSTM ćelije. To su kapija zaborava, koja odlučuje koje informacije treba odbaciti iz prethodnog stanja, kapija ulaza, koja odlučuje koje će nove informacije sa ulaza biti dodate u novo stanje, i kapija izlaza, koja određuje koje će informacije iz aktuelnog stanja biti poslate na aktuelni izlaz. Kao i za prethodne arhitekture, i za ovu će rezultati biti prikazani u sledećem poglavlju.

## 4 REZULTATI PRIMENE RAZLIČITIH ARHITEKTURA NEURALNIH MREŽA

U prethodnom poglavlju su predstavljene teorijske osnove principa funkcionisanja korišćenih tipova neuralnih mreža. U ovom poglavlju će biti predložen konkretan način na koji su one primenjene u svrhu estimacije teško merljivih parametara mehaničkog sistema.

Polazna tačka primene neuralnih mreža u estimaciji parametara koji se ne mere jesu upravo veličine koje se mere u datom sistemu. U ovom slučaju je, kao najjednostavnije merenje neke mehaničke veličine, izabrano merenje brzine, koje se najčešće izvodi pomoću enkodera. Kako bi se estimacija izvršavala bez obzira na brzinu kojom se pogon u datom trenutku kreće, odlučeno je da ulazni podatak bude ubrzanje, odnosno promena brzine pogonske mašine.

Odgovarajući skupovi podataka za treniranje neuralne mreže su generisani pomoću simulacije u programskom paketu *Simulink*. Simulacioni model pogona je prikazan na Sl. 4.1. Opsezi u kojima su varirani parametri pogona su prikazani u Tabeli I. Vrednosti parametara su u daljem radu sa njima normalizovane, a kao bazne vrednosti su uzete srednje vrednosti u opsegu za svaku od veličina. Tako su izlazi iz estimatora ograničeni na vrednosti između 0,5 i 1,5r.j. što je korisno radi ujednačenja težinskih faktora.



Slika 4.1: Blok dijagram sistema dve mase korišćen u simulaciji

Tabela I: Opsezi i bazne vrednosti ciljnih veličina

| Parametar       | Opseg           | Bazna vrednost |
|-----------------|-----------------|----------------|
| $J_I [kgm^2]$   | 0,0035 – 0,0105 | 0,007          |
| $K_k [Nm/rad]$  | 158,5 – 475,5   | 317            |
| $K_v [Nms/rad]$ | 0,075 – 0,225   | 0,15           |

Prva testirana arhitektura, predstavljena u poglavlju 3.1 je višeslojni perceptron. U ovom radu je dizajnirana jedna varijanta koja je trenirana pomoću dva različita skupa podataka, od kojih je jedan sačinjen od signala koji su dobijeni direktno iz simulacije, a drugi je dobijen dodavanjem Gausovog šuma na podatke iz prvog skupa. Usvojene su dimenzije skrivenih slojeva od 30 neurona u prvom i 15 u drugom sloju. Broj parametara koje treba istrenirati u ovakvoj mreži je 30543.

Zanimljivo je zapaziti da je treniranje na osnovu signala sa šumom mnogo brže završeno od treniranja na osnovu čistog signala. Razlog tome je što treniranje neuralne mreže protiče u traženju globalnog minimuma funkcije greške. Pri tome može da se desi da mreža zapadne u lokalni minimum, kroz koji se ne može dostići željena funkcija, ali veći poremećaji u trening podacima, kao što je šum, pomažu mreži da izađe iz lokalnog minimuma. Trening na osnovu signala sa šumom je završen posle 16h, dok je trening na osnovu čistog signala, ne dostigavši željene performanse, zaustavljen ručno, nakon više od 80h. Performanse dva višeslojna perceptrona dobijena na opisani način se nalaze u Tabeli II.

Pod performansama se podrazumeva srednji kvadrat greške između vrednosti dobijenih na izlazu neuralne mreže i očekivanih vrednosti, koje su korišćene u simulaciji za prikupljanje talasnog oblika brzine korišćenog za trening. Bitno je napomenuti da nema preklapanja između skupa podataka na kom je mreža trenirana i skupa na kom se testira u svrhu prikazivanja rezultata. Početni skup podataka je prethodno treniranju podeljen, da bi se obezbedilo testiranje performansi neuralne mreže podacima koji nisu viđeni tokom treniranja i validacije.

Tabela II: Performanse (srednje kvadratno odstupanje) višeslojnog perceptrona u zavisnosti od podataka korišćenih za trening pri testiranju različitim test podacima

|                                        |                         |                         |
|----------------------------------------|-------------------------|-------------------------|
| Trening podaci bez superponiranog šuma | 0,0002666               | 1,647                   |
| Trening podaci sa superponiranim šumom | 0,0005494               | 0,0014363               |
| Test podaci                            | Bez superponiranog šuma | Sa superponiranim šumom |

Zaključak koji se nameće na osnovu prikazanih rezultata je da se mreža trenirana trening podacima bez superponiranog šuma ne ponaša dobro kada joj se pri testiranju na ulaz dovedu podaci sa šumom. U ostalim slučajevima su performanse jako dobre. Pokazaće se da su rezultati bolji nego u slučaju nekih struktura koje će biti ispitane u nastavku, ali je veliki problem kod ovakve arhitekture dužina trajanja treninga.

Što se tiče drugog ispitanog tipa neuralne mreže, konvolucione neuralne mreže, arhitektura koja je usvojena se sastoji od 4 sloja konvolucije. U prvom skrivenom sloju primenjuje se 16 različitih filtara, u drugom 32, a u trećem i četvrtom po 64, što je ukupno 176 različitih filtara. Dimenzije samih filtara su varirane. Bez obzira na njih, broj parametara je višestruko smanjen u odnosu na broj parametara višeslojnog perceptrona. Ako svaki filter obuhvata 3 odbirka, ukupan broj parametara je 528. Ipak, da bi se uhvatile sporije promene koje se javljaju u okviru snimka, a koje mogu da sadrže korisne informacije, može se ukazati potreba za primenom filtara većih dimenzija. Zbog toga su isprobane različite dimenzije filtara, te stvaran broj parametara može da odstupa od gore navedenog, ali je i dalje značajno smanjen u odnosu na broj parametara kod višeslojnog perceptrona (30543). Pokazalo se i da je vreme potrebno za trening ovakvih mreža, u trajanju od nekoliko desetina minuta, značajno kraće od treninga za arhitekture višeslojnih perceptrona.

Ponovo su za trening korišćeni signali ubrzanja na strani motora dobijeni iz simulacije, u varijanti bez dodatog Gausovog šuma i sa njime. Dimenzija filtra je varirana. U tabeli III su date performanse različitih konvolucionih mreža, gde su filtri u svim slojevima jednakih dimenzija, dok su za svaku isprobanu dimenziju napravljene po dve varijante mreže, jedna koja koristi *dropout* metodu i jedna koja je ne koristi.

Na osnovu rezultata prikazanih u Tabeli III, jasno se može zaključiti da se bolje performanse postižu kada je u trening podatke uključena neka vrsta šuma. U poređenju mreža po dimenzijama filtra, generalno su se bolje pokazale one sa najmanjim filtrom. Primetno je da čak i kod testiranja čistim signalom bolje rezultate obično daju mreže istrenirane sa podacima sa superponiranim šumom. Razlog tome je to što je treniranje mreže bilo ograničeno brojem epoha, tako da je posle istog broja epoha, funkcija greške mreže trenirane sa šumom generalno bila bliža globalnom minimumu od one trenirane čistim podacima.

U tabeli su osenčene najbolje performanse koje se dobijaju ako je mreža testirana podacima u kojima takođe postoji šum, zato što će u praktičnoj primeni šum biti neizbežan.

Tabela III: Performanse (srednje kvadratno odstupanje) konvolucione neuralne mreže u zavisnosti od trening podataka i dimenzije filtra pri testu sa različitim test podacima

| Dimenzija filtra                                        | 3                       | 21       | 101      | 3                       | 21       | 101      |
|---------------------------------------------------------|-------------------------|----------|----------|-------------------------|----------|----------|
| Trening podaci bez superponiranog šuma                  | 0,000761                | 0,001427 | 0,001011 | 0,003287                | 0,002790 | 0,002106 |
| Trening podaci sa superponiranim šumom                  | 0,000694                | 0,001459 | 0,001122 | 0,001090                | 0,001871 | 0,001511 |
| Trening podaci bez superponiranog šuma + <i>dropout</i> | 0,000830                | 0,000667 | 0,000750 | 0,003422                | 0,002460 | 0,003354 |
| Trening podaci sa superponiranim šumom + <i>dropout</i> | 0,000791                | 0,001035 | 0,000963 | 0,001176                | 0,001419 | 0,001342 |
| Test podaci                                             | Bez superponiranog šuma |          |          | Sa superponiranim šumom |          |          |

LSTM je sledeća korišćena arhitektura, specijalizovana za obradu većih sekvencijalnih podataka promenljive dužine. U ovom radu je upotrebljen LSTM sloj iza nekoliko konvolucionih slojeva sa malim dimenzijama filtara. Na taj način konvolucionni slojevi obrađuju i uočavaju brze promene koje se javljaju u okviru signala, dok LSTM sloj služi da izvuče informacije iz dugotrajnijih i sporijih procesa koji mogu biti od značaja za estimaciju parametara na izlazu iz neuralne mreže. Usvojena je arhitektura koja se sastoji od dva konvoluciona sloja sa 16 i 32 filtra dimenzija 3, i jedan sloj LSTM sa 64 ćelije. Ponovo su testirane mreže i sa i bez *dropout*-a, sa različitim udelom šuma u trening podacima. Performanse su prikazane u tabeli IV.

Tabela IV: Performanse (srednje kvadratno odstupanje) kombinovane CNN i LSTM sa različitim trening i test podacima

|                                                         |           |                         |
|---------------------------------------------------------|-----------|-------------------------|
| Trening podaci bez superponiranog šuma                  | 0,0010461 | 0,005274                |
| Trening podaci sa superponiranim šumom                  | 0,0007509 | 0,0060012               |
| Trening podaci bez superponiranog šuma + <i>dropout</i> | 0,0013410 | 0,0017584               |
| Trening podaci sa superponiranim šumom + <i>dropout</i> | 0,0007766 | 0,0012137               |
| Test podaci                                             | Čisti     | Sa superponiranim šumom |

Kao i u prethodno analiziranim slučajevima, i ovde se u analizi dobijenih rezultata prednost daje arhitekturama koje imaju bolje performanse kada se na ulaz dovede signal koji ima značajniji udeo šuma. Razlog za to je sličnost sa uslovima koji će se imati pri implementaciji neuralne mreže u realan sistem upravljanja. Stoga su osenčena polja u kojima su najbolje ocenjene performanse dobijene testiranjem test podacima sa superponiranim šumom. Pokazalo se da je mreža dobijena bez *dropout* metode dala bolje performanse, ali to nije dovoljan razlog da se ona dobijena sa primenom *dropout* metode zanemari. Očekuje se da će u daljem istraživanju, koje podrazumeva primenu estimatora mehaničkih parametara na realan sistem, biti potrebna dodatna robusnost, koju *dropout* metoda, kao što je poznato, obezbeđuje.

## 5 ZAKLJUČAK

Na osnovu rezultata prikazanih u prethodnom poglavlju, može se zaključiti da su ostvareni dobri rezultati estimacije mehaničkih parametara primenom neuralnih mreža, a posebno kroz kombinovanje različitih arhitektura, konkretno konvolucione neuralne mreže i *long short-term memory* mreže. Drugi zaključak koji se nameće je da umetanje veštačkog šuma u podatke za treniranje ima pozitivan efekat na robusnost neuralne mreže formirane na taj način, kao i na brzinu treniranja, zbog mogućnosti „bekstva“ iz lokalnog minimuma, kao što je objašnjeno u 3. poglavlju.

Dalji koraci u razvoju ove teme će, pre svega, biti učinjeni sa ciljem da se estimator mehaničkih parametara zasnovan na ovom radu implementira u model pogona u Laboratoriji. U tu svrhu će biti potrebno obezbediti dodatne podatke za treniranje izabranog tipa neuralne mreže. Plan je da se podaci formiraju u simulaciji u kojoj će biti uvažene i različite karakteristike trenja koje se javlja u sistemu. Na taj način se sa različitim ulazima koji treba da daju slične izlaze postiže još veća robusnost, koja će biti ključna zbog prirode šuma kod merenja brzine enkoderom. Naime, šum koji se javlja u eksperimentu, ne može se uvek opisati ni Gausovom ni uniformnom raspodelom, tako da je očekivano da će opisivanje šuma takođe zahtevati posebnu pažnju u daljem radu.

## 6 LITERATURA

- [1] B. Jeftenić, M. Bebić, S. Štatkić, *Višemotorni električni pogoni*, Akademska misao, 2011
- [2] S. Vukojičić, L. Ristić, G. Kvašček, „Comparison Between PI and Model Predictive Control of Two Mass Resonant Mechanical System“, *2022 7th International Conference on Environment Friendly Energies and Applications (EFEA)*, Bagatelle Moka MU, Mauritius, 2022, pp. 1-6
- [3] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA: MIT Press, 2016. [Online]. Available: <http://www.deeplearningbook.org>