

# Upravljanje robotom pomoću električnih impulsa mišića

---

**Marković, Lucija**

**Master's thesis / Diplomski rad**

**2019**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

*Permanent link / Trajna poveznica:* <https://urn.nsk.hr/urn:nbn:hr:235:879065>

*Rights / Prava:* [In copyright](#)/[Zaštićeno autorskim pravom.](#)

*Download date / Datum preuzimanja:* **2025-03-02**

*Repository / Repozitorij:*

[Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# **DIPLOMSKI RAD**

**Lucija Marković**

Zagreb, 2019. godina.

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# DIPLOMSKI RAD

Mentor:

Prof. dr. sc. Bojan Jerbić, dipl. ing.

Student:

Lucija Marković

Zagreb, 2019. godina.

Izjavljujem da sam ovaj rad izradila samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem se profesoru dr. sc. Bojanu Jerbiću i asistentu dr. sc. Bojanu Šekoranji na pomoći, sugestijama i strpljenju prilikom izrade diplomskog rada.

Također se želim zahvaliti obitelji na podršci i razumijevanju tijekom studiranja.

Lucija Marković



SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite  
Povjerenstvo za diplomske radove studija strojarstva za smjerove:  
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment,  
inženjerstvo materijala te mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum:	Prilog:
Klasa:	
Ur. broj:	

## DIPLOMSKI ZADATAK

Student: **LUCIJA MARKOVIĆ** Mat. br.: 0035197362

Naslov rada na hrvatskom jeziku: **Upravljanje robotom pomoću mjerenja električnih impulsa mišića**

Naslov rada na engleskom jeziku: **Robot control by measuring muscle electrical impulses**

Opis zadatka:

Za upravljanje sustavom temeljenog na interakciji čovjeka i robota (HRI), važno je poznavati silu kojom čovjek djeluje na okolinu, tj. silu koja proizlazi iz mišića. Znanje o individualnim silama mišića važno je za stjecanje uvida u mehanizme kontrole pokreta. Zbog toga je bitno razviti algoritam koji će omogućiti estimaciju sile razvijene u mišiću. Jedna od obećavajućih tehnika koja se u tu svrhu koristi je elektromiografija, čija su prednost senzori malih dimenzija, lakoća postavljanja i neinvazivnost (pri korištenju površinskih elektroda). Prikupljeni signal se analizira te se njegove značajke koriste za izradu algoritma procjene opterećenja.

U radu je potrebno istražiti mogućnost upravljanja robotom putem električnih impulsa mišićnih živaca. Razvijeni model potrebno je primijeniti koristeći opremu dostupnu u Laboratoriju za projektiranje izradbenih i montažnih sustava.

U radu je potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:  
02. svibnja 2019.

Rok predaje rada:  
04. srpnja 2019.

Predviđeni datum obrane:  
10. srpnja 2019.  
11. srpnja 2019.  
12. srpnja 2019.

Zadatak zadao:  
prof. dr. sc. Bojan Jerbić

Predsjednica Povjerenstva:  
prof. dr. sc. Biserka Runje

## SADRŽAJ

SADRŽAJ .....	I
POPIS SLIKA .....	II
POPIS TABLICA .....	IV
POPIS OZNAKA .....	V
SAŽETAK .....	VI
SUMMARY .....	VII
1. UVOD .....	1
2. TEORIJSKA OSNOVA .....	2
2.1. Elektromiografija .....	2
2.1.1. Mišić .....	2
2.1.2. Obrada elektromiografskog signala [2] .....	6
2.1.3. Veza elektromiografskog signala i sile u mišićima .....	9
2.2. Umjetne neuronske mreže .....	11
2.2.1. Način rada neuronske mreže .....	15
3. RAZRADA ZADATKA .....	18
3.1. Mjerenje elektromiografskog signala .....	18
3.2. Priprema podataka za učenje neuronske mreže .....	20
3.3. Analiza rada neuronske mreže i problema značajki signala .....	28
3.4. Drugi pristup –neuronska mreža jednog ispitanika .....	42
3.5. Mogućnost ponovljivog korištenja neuronske mreže .....	48
3.6. Program za procjenu sile dvoglavog nadlaktičnog mišića u stvarnom vremenu .....	63
3.7. Rad sustava s ostalim mišićima .....	66
4. ZAKLJUČAK .....	73
LITERATURA .....	75
PRILOZI .....	77

## POPIS SLIKA

Slika 1.	Struktura mišića [4] .....	3
Slika 2.	Motorna jedinica [2] .....	4
Slika 3.	Model detekcije signala jednog mišićnog vlakna [2] .....	5
Slika 4.	Neobrađeni elektromiografski signal [2] .....	6
Slika 5.	Koraci obrade EMG signala [5] .....	8
Slika 6.	Hill-ov model mišića [8] .....	10
Slika 7.	Biološki akson [11] .....	12
Slika 8.	Odstupanje izlaza kroz iteracije [12] .....	14
Slika 9.	Aktivacije funkcije [13] .....	15
Slika 10.	Višeslojna neuronska mreža [14] .....	15
Slika 11.	Muscle SpikerShield Pro [15] .....	18
Slika 12.	Dvoglavi nadlaktični mišić na koji su postavljene elektrode [16] .....	18
Slika 13.	Neobrađeni signal koji Arduino šalje MATLAB-u .....	19
Slika 14.	Filtriran i ispravljen signal .....	19
Slika 15.	EMG signal nakon filtriranja i usrednjavanja .....	20
Slika 16.	Položaj ruke tijekom prikupljanja značajki [17] .....	22
Slika 17.	Procjena sile razvijene u mišiću .....	24
Slika 18.	Amplitude EMG signala kod ispitanika tijekom podizanja tereta od 5 kg .....	25
Slika 19.	Prikupljene značajke po ispitaniku .....	26
Slika 20.	Dobiveni izlaz mreže u usporedbi sa željenim izlazom .....	27
Slika 21.	Testiranje mreže na novom ispitaniku .....	28
Slika 22.	Značajke signala ispitanika 4 kod mjerenja opterećenja do 10 kg .....	29
Slika 23.	Dotrenirana neuronska mreža .....	30
Slika 24.	Iznosi srednje apsolutne vrijednosti za različita opterećenja po ispitanicima .....	31
Slika 25.	Usporedba srednjih vrijednosti prve značajke za sve slučajeve .....	32
Slika 26.	Iznosi nagiba srednje apsolutne vrijednosti signala za različita opterećenja po ispitanicima .....	34
Slika 27.	Usporedba srednjih vrijednosti druge značajke za sve slučajeve .....	35
Slika 28.	Iznosi duljine valnog oblika signala za različita opterećenja po ispitanicima .....	37
Slika 29.	Usporedba srednjih vrijednosti treće značajke za sve slučajeve .....	38
Slika 30.	Iznosi energije signala za različita opterećenja po ispitanicima .....	40
Slika 31.	Usporedba srednjih vrijednosti četvrte značajke za sve slučajeve .....	41
Slika 32.	Neuronska mreža na podacima jednog ispitanika, naučeni i nepoznati podaci od istog mjerenja .....	43
Slika 33.	Neuronska mreža jednog ispitanika testirana na nepoznatim podacima .....	43
Slika 34.	Druga neuronska mreža jednog ispitanika, podaci tijekom opterećenja od 4 kg nepoznati mreži .....	44
Slika 35.	Treća neuronska mreža jednog ispitanika, podaci tijekom opterećenja od 2 i 4 kg nepoznati mreži .....	45
Slika 36.	Četvrta neuronska mreža jednog ispitanika, podaci tijekom opterećenja od 1, 2 i 4 kg nepoznati mreži .....	46
Slika 37.	Peta neuronska mreža jednog ispitanika, podaci tijekom opterećenja od 5 kg i bez opterećenja nepoznati mreži .....	47
Slika 38.	Iznosi srednje apsolutne vrijednosti za različita opterećenja na jednom ispitaniku u više mjerenja .....	50

Slika 39.	Usporedba srednjih vrijednosti prve značajke višestruko mjerenih na jednom ispitaniku i srednjih vrijednosti tih mjerenja i mjerenja ostalih ispitanika.....	51
Slika 40.	Iznosi nagiba srednje apsolutne vrijednosti za različita opterećenja na jednom ispitaniku u više mjerenja .....	52
Slika 41.	Usporedba srednjih vrijednosti druge značajke višestruko mjerenih na jednom ispitaniku i srednjih vrijednosti tih mjerenja i mjerenja ostalih ispitanika.....	53
Slika 42.	Iznosi duljina valnog oblika signala za različita opterećenja na jednom ispitaniku u više mjerenja .....	54
Slika 43.	Usporedba srednjih vrijednosti treće značajke višestruko mjerenih na jednom ispitaniku i srednjih vrijednosti tih mjerenja i mjerenja ostalih ispitanika.....	55
Slika 44.	Iznosi energije signala za različita opterećenja na jednom ispitaniku u više mjerenja .....	56
Slika 45.	Usporedba srednjih vrijednosti četvrte značajke višestruko mjerenih na jednom ispitaniku i srednjih vrijednosti tih mjerenja i mjerenja ostalih ispitanika.....	57
Slika 46.	Odziv neuronske mreže na nepoznate podatke mjerenja 3.....	58
Slika 47.	Odziv neuronske mreže na djelomično nepoznate podatke mjerenja 3, poznati podaci za opterećenje 3 kg.....	59
Slika 48.	Odziv neuronske mreže na djelomično nepoznate podatke mjerenja 3, djelomično poznati podaci za opterećenje 3, 4 i 5 kg.....	60
Slika 49.	Odziv neuronske mreže na nepoznate podatke mjerenja 2.....	60
Slika 50.	Odziv neuronske mreže na djelomično nepoznate podatke mjerenja 2, djelomično poznati podaci za opterećenje 3 kg .....	61
Slika 51.	Odziv neuronske mreže na nepoznate podatke mjerenja 2 s uvećanim podacima za učenje.....	62
Slika 52.	Korisničko sučelje .....	64
Slika 53.	Odabir početka i kraja signala opterećenja .....	65
Slika 54.	Estimacija sile na ispitaniku 1 prilikom podizanja tereta od 5 kg .....	66
Slika 55.	Troglavi nadlaktični mišića[19] .....	67
Slika 56.	Položaj ruke i tijela tijekom prikupljanja značajki za troglavi nadlaktični mišić [20] .....	67
Slika 57.	Prikupljene značajke za signal tricepsa .....	68
Slika 58.	Odziv neuronske mreže tricepsa .....	69
Slika 59.	Mišići podlaktice [21].....	70
Slika 60.	Značajke pri različitim opterećenjima, ulnarni pregibač zapešća .....	70
Slika 61.	Značajke pri različitim opterećenjima, ulnarni ispružać zapešća .....	71
Slika 62.	Dodatni senzori za procjenu sila mišića podlaktice [22], [23] .....	72



**POPIS TABLICA**

Tablica 1. Normalizirane značajke EMG signala ovisno o opterećenju .....	21
Tablica 2. Karakteristike ispitanika .....	22
Tablica 3. Procjena sile bicepsa za različita opterećenja .....	23
Tablica 4. Iznosi srednje apsolutne vrijednosti EMG signala više ispitanika.....	32
Tablica 5. Iznosi nagiba srednje apsolutne vrijednosti EMG signala više ispitanika .....	35
Tablica 6. Iznosi duljina valnog oblika EMG signala više ispitanika .....	38
Tablica 7. Iznosi energije EMG signala više ispitanika.....	41
Tablica 8. Odstupanja od željenog izlaza neuronskih mreža za različite slučajeve .....	48
Tablica 9. Iznosi srednje apsolutne vrijednosti EMG signala jednog ispitanika u više mjerjenja .....	51
Tablica 10. Iznosi nagiba srednje apsolutne vrijednosti EMG signala jednog ispitanika u više mjerjenja .....	53
Tablica 11. Iznosi duljina valnog oblika EMG signala jednog ispitanika u više mjerjenja.....	55
Tablica 12. Iznosi energije EMG signala jednog ispitanika u više mjerjenja .....	57
Tablica 13. Odstupanja od željenog izlaza neuronskih mreža za različite slučajeve na više mjerjenja .....	62

## POPIS OZNAKA

Oznaka	Jedinica	Opis
$b$		Gauss-ov bijeli šum
$d$	m	Udaljenost bicepsa od lakatnog zgloba
$E$		Pogreška učenja
$e$		Podražajni impuls
$emgs$		Modelirani elektromiografski signal
$F_b$	N	Sila dvoglavog nadlaktičnog mišića
$F_t$	N	Opterećenje tereta
$F_{tric}$	N	Sila troglavog nadlaktičnog mišića
$h$		Akcijski potencijal motorne jedinice
$I$		Broj neurona ulaznog sloja
$J$		Broj neurona skrivenog sloja
$K$		Broj neurona izlaznog sloja
$l_1$	M	Duljina podlaktice
$m_1$	kg	Masa podlaktice
$m_2$	kg	Masa šake
$m$		Korak učenja
$m_t$	kg	Masa tereta
$MAV$		Srednja apsolutna vrijednost
$MAVSLP$		Nagib srednje apsolutne vrijednosti
$N$		Broj uzoraka u segmentu signala
$r_1$	M	Udaljenost od centra mase podlaktice do lakta
$s$		Izlazni vektor skrivenog sloja neuronske mreže
$SSI$		Jednostavni kvadratni integral
$sum$		Funkcija sume težina i ulaza
$v$		Vektor težina veza ulaznog i skrivenog sloja
$w$		Vektor težina veza skrivenog i izlaznog sloja
$WL$		Duljina valnog oblika
$x$		Vektor ulaznih signala neuronske mreže
$x_i$		$i$ -ti uzorak signala
$y$		Izlazni vektor neuronske mreže
$\alpha$	°	Kut pregiba tijela
$\gamma$		Aktivacijska funkcija
$\eta$		Koeficijent brzine učenja
$\vartheta$		Parametar učenja

## **SAŽETAK**

Istraživanja na području interakcije robota i čovjeka od velike su važnosti u današnje vrijeme. Cilj tog područja je izrada sustava koji će se uklopiti u čovjekovo okruženje i raditi na čovjeku prirodni način te uspostavljanje kvalitetnog međudjelovanja čovjeka i robotskog sustava. U ovom radu razrađena je ideja korištenja elektromiografskog signala kao informacije o silama u mišićima ruke. Time bi se robotskom sustavu dao uvid u sile kojima čovjek djeluje na okolinu. U radu je razjašnjena teorija elektromiografije i neuronske mreže, algoritma korištenog za estimaciju sile. Zatim je izrađen sustav koji estimira silu dvoglavog nadlaktičnog mišića prema podacima prikupljenima na više ispitanika. Nakon toga su analizirane značajke signala kako bi se dobio uvid u razlog velikih odstupanja dobivenih rezultata od željenih. Na temelju analize donesen je zaključak da je potrebno razraditi drugačiji model. Napravljen je sustav prema podacima samo jednog ispitanika te obrađena analiza s podacima prikupljenima u više mjerenja. U korisničkom sučelju implementiran je sustav u realnom vremenu. Na kraju je proučeno korištenje sustava na ostalim mišićima nadlaktice i podlaktice.

Ključne riječi: mišić; sila; elektromiografija; neuronska mreža; Arduino; MATLAB;

## **SUMMARY**

Nowadays, research in the field of Human Robot Interaction is of great importance. The goal of this field is production of effective interaction and creation of systems which would fit into the human environment and work in a more natural way. This paper presents the idea of using electromyographic signal as information on the force developed in the muscle. That would give the robot system an insight into the forces by which human affects the environment.

This paper deals with the theory of electromyography and artificial neural network, the algorithm used for force estimation. Firstly, a system for force estimation of biceps brachii was developed using data from multiple subjects. Afterwards, the signal features were analyzed to gain insight into the reason for large deviations of the obtained results in comparison to the ones that are desired. According to conclusions from the analysis, another system was developed using a different approach. The system was made using data from only one subject and the data from different measurements were analyzed. This system was implemented in real time in the user interface. Finally, the use of the system on the other muscles of the upper arm and the forearm was researched.

Key words: muscle; force; electromyography; neural network; Arduino; MATLAB;

## 1. UVOD

Interakcija čovjeka i robota, tj. HRI – Human-Robot Interaction, područje je znanosti koje se bavi proučavanjem, konstruiranjem i evaluacijom robotskih sustava korištenih u suradnji s čovjekom. To je multidisciplinarno znanstveno polje te objedinjuje područja umjetne inteligencije, robotike, socijalnih znanosti, razumijevanja prirodnog jezika i interakcije čovjeka i računala (eng. Human-computer interaction, HCI).

Čest način povezivanja čovjeka i robota jest implementacija vizijskog sustava za praćenje pokreta. Ona omogućava oponašanje pokreta koje čini čovjek od strane robotskog sustava. No, korištenjem samo vizijskog sustava nije moguće dobiti informaciju o silama kojima čovjek djeluje na svoju okolinu. Tu informaciju moguće je dobiti korištenjem senzora sila, ili u ovom slučaju, korištenjem elektromiografskog signala. Korišten je elektromiografski senzor zbog svojih malih dimenzija i lakoće postavljanja.

Za estimaciju sila koje se razvijaju u mišićima potrebno je razviti sustav koji uzima podatke sa senzora, vrši obradu signala te pomoću matematičkog modela ili algoritma preslikava te vrijednosti u vrijednosti sila. Potrebno je izraditi mehaničke modele prema kojima bi se odredila sila u mišićima u graničnim uvjetima, tj. prilikom maksimalnog odnosno minimalnog opterećenja. Integracijom tih modela u rješenja dobivenih iz korištenog algoritma moguće je procijeniti sile koje se razvijaju u mišićima kod korisnika sustava ovisno o njegovim karakteristikama.

Za izradu takvog sustava potrebno je proučiti odnos sile i elektromiografskog signala. Prema nekim istraživanjima taj odnos je nepredvidiv, dok se u drugima pokazao za određene slučajeve linearan. U ovom radu istražena je veza elektromiografskog signala i sila tijekom izometričke kontrakcije mišića jer prema dosadašnjim istraživanjima prilikom te kontrakcije postoji veza EMG signala i sile.

## 2. TEORIJSKA OSNOVA

### 2.1. Elektromiografija

Elektromiografija je proučavanje funkcije mišića kroz istraživanje električnih signala koji proizlaze iz mišića [1], odnosno eksperimentalna tehnika koja se bavi razvojem, prikupljanjem i analizom električnih signala mišića, mioelektričnih signala [2]. Taj signal pripada biomedicinskim signalima, tj. električnim signalima prikupljenima s organa koji predstavljaju fizičku varijablu od interesa. Funkcija su vremena i moguće ih je opisati po amplitudi, frekvenciji i fazi. Elektromiografski signal mjeri električne struje izazvane u mišićima prilikom njihove kontrakcije i predstavlja neuromuskularnu aktivnost [3]. Ovaj signal je vrlo složen te na njega utječu anatomska i fiziološka svojstva mišića, upravljačka shema perifernog živčanog sustava, instrumenti i procesi korišteni za detekciju.

Elektromiografija sadrži dvije vrste važnih informacija, vrijeme aktivnosti mišića i relativan intenzitet aktivnosti mišića. Te informacije su od koristi u širokom rasponu istraživanja, od osnovnih medicinskih i fizioloških studija do fizioterapije, rehabilitacije, sporta, razvoja medicinskih pomagala te u interakciji ljudskog tijela s industrijskim proizvodima [2].

Neke od prednosti elektromiografije su to što:

- daje uvid u aktivnosti mišića u stvarnom vremenu,
- omogućuje mjerenje funkcije mišića,
- pomaže pri donošenju odluka kod operativnih zahvata,
- omogućuje analizu mišića u svrhu poboljšanja sportskih ili rehabilitacijskih aktivnosti,
- detektira reakcije mišića u ergonomske istraživanjima.


#### 2.1.1. Mišić

Mišić je sastavljen od svežnja specijaliziranih stanica sa sposobnošću kontrakcije i relaksacije. Osnovna fiziološka svojstva mišićnog tkiva su ekscitabilnost, kontraktibilnost, mogućnost istezanja i elastičnost. Četiri glavne funkcije mišićnih tkiva su stvaranje pokreta, pomicanje supstanca unutar tijela, pružanje stabilnosti te stvaranje topline. Prema strukturi, svojstvima kontrakcije i kontrolnim mehanizmima, razlikuju se tri vrste mišićnih tkiva: glatki mišići, srčani

mišić i poprečno-prugasti ili skeletni mišić. Elektromiografija se primjenjuje u proučavanju skeletnih mišića. [3]

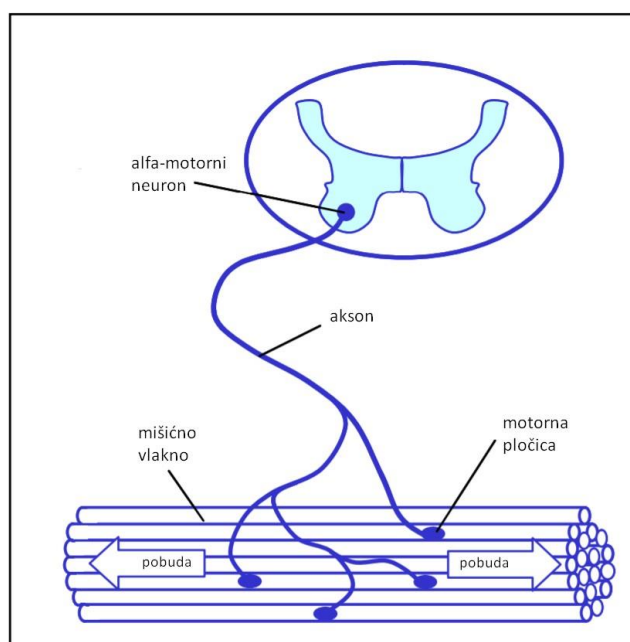
Poprečno-prugasti mišići angažirani su u gibanjima kao što su pokreti tijela. Mišiće pokreće živčani sustav preko sinapsi. Kada živčani impuls dođe do mišićnog tkiva, prouzroči kontrakciju mišića, te su tijekom kontrakcije viskozno-elastična svojstva mišića izmijenjena.

Poprečno-prugasto mišićno tkivo sastoji se od mišićnih vlakana, tj. višejezgrenih mišićnih stanica. Mišićno vlakno građeno je od mišićnih vlaknaca ili miofibrila koji se protežu cijelom duljinom mišićnog vlakna, a uzdužno su podijeljene poprečnim Z-membranama na segmente zvane sarkomere. Sarkomera je strukturna jedinica mišića, najmanji funkcionalni dio mišića. Sastoji se od niti miozina i aktina, koje su polimerizirane molekule bjelančevina izduženog oblika. Niti miozina su deblje i oko njih je smješteno šest tanjih niti aktina. Mišićno vlakno sastoji se od velikog broja sarkomera posloženih u seriju. Raspored sarkomera u seriji u paralelno raspoređenim vlaknima daje toj vrsti mišića naziv poprečno-prugasti mišići. Detaljan prikaz strukture mišića nalazi se na slici 1.



**Slika 1. Struktura mišića [4]**

Najmanja funkcionalna jedinica koja opisuje neuralnu kontrolu kontrakcije mišića naziva se motorna jedinica, slika 2. Definiraju je stanično tijelo, dendriti i višestruke grane aksona motornog neurona te mišićna vlakna koja taj neuron podražuje. Koristi se pojam jedinica jer se prilikom podražaja motorne živčane stanice sva mišićna vlakna unutar te motorne jedinice istovremeno kontrahiraju [2].



**Slika 2. Motorna jedinica [2]**

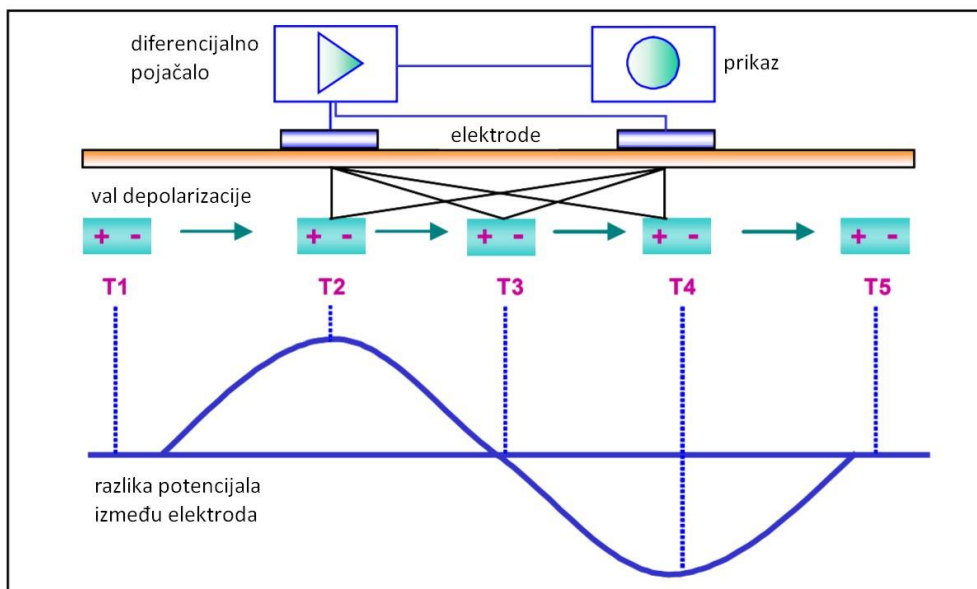
Bitan faktor u fiziologiji mišića je sposobnost podraživosti (ekscitabilnosti) mišićnih vlakana neuralnim upravljanjem. Taj fenomen objašnjen je modelom polupropusne membrane koji opisuje električna svojstva sarkoleme (membrane mišića). Ionska ravnoteža unutar i izvan mišićne stanice tvori potencijal mirovanja na membrani u vrijednosti od oko -80 do -90 mV kada mišić nije kontrahiran. Ova razlika u potencijalu koju održavaju fiziološki procesi (ionska pumpa) rezultira negativnim nabojem unutar stanice u odnosu na vanjsku površinu. Aktivacija motorne živčane stanice uzrokovana centralnim živčanim sustavom ili refleksom, rezultira provođenjem podražaja uzduž motornog živca. Nakon oslobađanja neurotransmitera na motornim pločicama, posebnim sinapsama koje predstavljaju neuromuskularnu vezu, na mišićnom vlaknu podraženom tom motornom jedinicom stvara se potencijal motornih pločica. Karakteristike difuzije membrane mišićnog vlakna nakratko su izmijenjene i natrijevi kationi ulaze u stanicu. Time je uzrokovana depolarizacija membrane te se odmah potom membrana vraća u početno stanje povratnom razmjenom iona mehanizmom ionske pumpe, tj. repolarizacijom.[2]



Ako potencijal membrane prijeđe određeni prag navalom natrijevih kationa, depolarizacija membrane izaziva skok akcijskog potencijala od  $-80$  mV na vrijednost do  $+30$  mV. Taj monopolarni električni nalet vraća se u početno stanje repolarizacijom. Počevši od motornih pločica akcijski potencijal širi se kroz mišićno vlakno u oba smjera i unutar vlakna sustavom cjevčica. [2]

Akcijski potencijal izaziva mehanizam kontrakcije. Miozinske niti imaju poprečne izdanke koji na svojim krajevima imaju glavice od 150 molekula miozina. One se mogu prihvaćati za aktinsku nit. Podražaj potiče kalcijeve ione na izlazak iz sarkoplazmatskog retikuluma što omogućuje vezanje miozinske glave na aktin. Glavica molekule miozina prihvaća se okomito na aktinsku nit, potom se zahvaćena spušta za  $45$  stupnjeva povlačeći aktinsku nit uz miozinsku. Adenozin trifosfat ATP veže se na miozinsku glavu i oslobađa je veze s aktinom te se glavica miozina ponovno uspravlja i proces započinje iz početka.

Ciklus depolarizacije-repolarizacije stvara val depolarizacije, električni dipol, koji putuje preko površine mišićnog vlakna. Za mjerenje tog signala koriste se bipolarnе elektrode i diferencijalno pojačalo. Na slici 3. prikazan je model detekcije signala s jednog mišićnog vlakna.



**Slika 3. Model detekcije signala jednog mišićnog vlakna [2]**

Model razjašnjava kako monopolarni akcijski potencijal stvara bipolarni signal u procesu diferencijalnog pojačanja. Kako val depolarizacije putuje mišićnim vlaknom, on stvara razliku potencijala na mjestima postavljanja elektroda. U trenutku T2 električni dipol se nalazi blizu

prve elektrode, što se očituje pozitivnom razlikom potencijala. Val je na jednakoj udaljenosti od obje elektrode u trenutku T3, te je time razlika potencijala jednaka nuli. Kada se val depolarizacije približi drugoj elektrodi, zabilježena ne negativna razlika potencijala elektroda. [2]

Pošto se motorna jedinica sastoji od mnogo mišićnih vlakana, par elektroda vidi magnitude svih podraženih vlakana unutar te jedinice. One se zbrajaju u akcijski potencijal motorne jedinice, MUAP (Motor Unit Action Potential), koji ovisno o geometrijskoj orijentaciji vlakana u odnosu na mjesta na kojima su postavljene elektrode može biti različite veličine i oblike. [2]

Svi akcijski potencijali motorne jedinice svih aktivnih motornih jedinica koje se nalaze u području osjetljivosti elektroda su superponirani i promatra ih se kao bipolarni signal sa simetričnom raspodjelom pozitivnih i negativnih amplituda. [2]


Pojednostavljen model elektromiografskog signala prikazan je jednadžbom (1)

$$emgs(n) = \sum_{r=0}^{N-1} h(r)e(n-r) + b(n), \quad (1)$$

gdje  $emgs(n)$  predstavlja modelirani EMG signal,  $e(n)$  podražajni impuls,  $h(r)$  akcijski potencijali motorne jedinice,  $b(n)$  Gauss-ov bijeli šum te N broj podraženih motornih jedinica. [3]

### 2.1.2. Obrada elektromiografskog signala [2]

Nefiltrirani i neobrađeni signal dobiven mjerenjem superponiranih MUAP-a naziva se neobrađeni EMG signal, slika 4.



**Slika 4. Neobrađeni elektromiografski signal [2]**

Kada mišić nije kontrahiran, u prikazu mjerenja vidljiva je nulta linija EMG signala, uz moguć šum. Šum nulte linije neobrađenog EMG signala ovisi o više faktora, kao što su kvaliteta pojačala, elektroda, priprema mjesta postavljanja elektroda te vanjski šum.

Zdravi opuštteni mišić ne prikazuje značajnu EMG aktivnost zbog izostanka depolarizacije i akcijskog potencijala. Pikovi neobrađenog EMG signala su po prirodi nasumičnog oblika. Set aktivnih motornih jedinica unutar matrice raspoloživih motornih jedinica konstantno se mijenja. Može doći do slučaja da su dvije ili više motorne jedinice istovremeno podražene, te one, ako su smještene u blizini elektroda, stvaraju vrlo jak superponirani vrh. Korištenjem algoritama za 'glačanje' (usrednjavanje) signala, npr. pomični prosjek, nereproduktivni sadržaj se eliminira ili minimizira.

Na oblik i karakteristike EMG signala utječu:

- svojstva potkožnog tkiva – električna provodljivost ljudskog tijela ovisi o vrsti tkiva, debljini tkiva, fiziološkim promjenama i temperaturi. Kod tih karakteristika postoji velika varijabilnost te ona onemogućava direktnu usporedbu amplitudnih parametara bez dodatne obrade signala.
- fiziološko preslušavanje (eng. Crosstalk) – može se dogoditi da su obližnji mišići također detektirani elektrodama, ili pikovi EKG signala mogu ometati EMG signal,
- promjena međusobnog položaja elektroda i mišića – problem kod dinamičkih mjerenja,
- artefakti uslijed pomaka elektroda,
- vanjski šum – uzrokovan neispravnim uzemljenjem vanjskih uređaja, šum gradske mreže 50 Hz,
- elektrode i pojačala.

Raspon neobrađenog EMG signala je između +/- 5 mV, a frekvencijskog sadržaja je u rasponu 6 do 500 Hz, s najvišom frekvencijskom snagom između 20 i 150 Hz. Kako bi se točno prenio cjelokupni frekvencijski spektar, brzina uzorkovanja mora biti najmanje dvostruko veća od maksimalne očekivane frekvencije signala zbog Nyquistovog teorema prema kojemu je poznato da uzorkovanje signala preniskom frekvencijom rezultira aliasingom. Prema tome bi EMG signal trebalo uzorkovati frekvencijom od najmanje 1 kHz.

Prvi korak obrade signala je ispravljanje. Sve negativne amplitude pretvaraju se u pozitivne zrcaljenjem u odnosu na nultu liniju. Glavni razlog za ispravljanje signala je što se time


omogućava izračunavanje nekih od standardnih amplitudnih parametara kao što je srednja vrijednost signala, koja u neobrađenom signalu iznosi nula.

Kao što je već rečeno, zato što se skup u danom trenutku aktivnih motornih jedinica stalno mijenja i zbog toga što je način na koji su akcijski potencijali motornih jedinica superponirani proizvoljan, EMG signal je po karakteru nasumičan. Rezultat toga je činjenica da se neobrađeni EMG uzorak ne može ponoviti u precizno jednakom obliku. Stoga se nereproduktivni dio signala minimizira primjenom algoritama za usrednjavanje signala koji iscrtavaju srednji trend signala. Eliminiraju se strmi šiljci u signalu te on poprima 'linearnu omotnicu'. Algoritmi koji se koriste u tu svrhu su:

- pomični prosjek (Moving average) – određena količina podataka unutar vremenskog okvira kojega definira korisnik je uprosječena korištenjem tehnike kliznog prozora. Dobivena je informaciju o površini ispod signala u odabranom dijelu signala. Ako se koristi na ispravljenom signalu, naziva se još i prosječna ispravljena vrijednost (Average Rectified Value – AVR).
- korijen srednjeg kvadrata (Root Mean Square - RMS) – odražava srednju snagu signala na temelju izračuna kvadratnog korijena.

Obje metode zasnivaju se na vremenskom prozoru. U dinamičkim istraživanjima koriste se vremenska trajanja od 20 ms, za vrlo brze pokrete, skokove, reflekse, do 500 ms, za spore pokrete ili mirovanje.

Kao alternativa navedenim metodama, u istu svrhu može se koristiti i nisko propusni filter s graničnom frekvencijom oko 6 HZ, npr. Butterworthov filter drugog ili višeg reda.



**Slika 5. Koraci obrade EMG signala [5]**

Jedan od velikih nedostataka svake EMG analize je snažan utjecaj uvjeta mjerenja na amplitudne podatke. Oni mogu varirati ovisno o mjestu postavljanja elektroda, osoba na kojima se vrši mjerenje te čak i kod ponovnog mjerenja istog mišića na istoj osobi. Jedno od rješenja je normalizacija prema referentnoj vrijednosti, npr. maksimalnoj voljnoj vrijednosti kontrakcije (Maximum Voluntary Contraction – MVC). Amplitudna normalizacija ne mijenja oblik EMG krivulja, već ih skalira u odnosu na y-os. Glavni efekt normalizacije je minimizacija varijabilnosti uvjeta detekcije. Uz to, mijenja se mjerna jedinica podataka iz milivolta u postotak odabrane referentne vrijednosti.

### **2.1.3. Veza elektromiografskog signala i sile u mišićima**

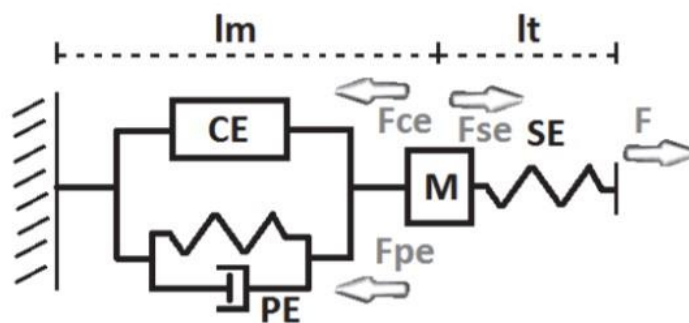
Elektromiografska aktivacija preliminarni je uvjet za razvoj sile i očekuje se bliska veza između tih mjera. Nažalost, korelacija među parametrima može uvelike varirati unutar svojih karakteristika. U tipičnom slučaju, odnos EMG-a i sile je krivuljno-linearano, što znači da je pri većim silama potreban proporcionalno veći EMG za povećanje sile. [2]

Amplituda elektromiografskog signala može se također protumačiti kao mjera relativne napetosti mišića. EMG signal obrađen linearnom omotnicom često je korišten za usporedbu odnosa EMG - napetost, pogotovo u slučaju kada se napetost mijenja s vremenom. Kod eksperimenata s konstantnom napetošću razrađena je ideja da je prosječna vrijednost ispravljenog EMG signala mjera napetosti. U istraživanjima su prijavljeni i linearni i nelinearni odnosi amplitude EMG signala i napetosti. Postoje značajna istraživanja o korištenju EMG zapisa za procjenu mišićnih sila, ali rezultati su često mješovitog uspjeha. Estimacije sila se računaju na temelju ili ispravljenog signala ili nakon odgovarajuće obrade ispravljenog signala nisko propusnim filtrom. [6]

Ideja da su magnituda i intenzitet EMG signala barem kvalitativno vezani za silu koju proizvodi mišić u danim uvjetima prihvaćena je u znanstvenim krugovima. No točna kvantitativna priroda tog odnosa tema je mnogih znanstvenih debata. Razlog tome je izrazito nelinearna, ovisna o vremenu, ovisnost tih signala te teškoća mjerenja EMG signala s dobrom dosljednošću i ponovljivošću. [7]

Univerzalni matematički model ljudskog mišića još nije razvijen. Postavljeno je mnogo modela od kojih je svaki pogodan za vrlo specifičnu primjenu. Jedan od često korištenih modela je Hill-ov model mišića, slika 6. Hill je bio pionir u modeliranju mišića, te je njegov model često

podloga drugih modela. Moguće ga je predstaviti kao mehaničku strukturu od tri elementa. Prvi element je kontraktilni element koji stvara silu zbog aktivacijskog signala. Drugi je paralelni element koji sadrži viskozno-elastična svojstva vezivnih tkiva mišića. Treći element je serijski element koji predstavlja tetive i unutarnju elastičnost miofilamenata. Mišićna masa predstavljena je inercijskim elementom mase  $M$ . Mišić se prilikom stvaranja sile skraćuje i povlači vezivni dio.



Slika 6. Hill-ov model mišića [8]

Sila mišića u kontraktilnom elementu CE ovisi o brzini mišića, duljini mišićnog vlakna i aktivaciji mišića koja je vezana uz elektromiografski signal. Sila paralelnog elementa PE ovisi o duljini mišićnog vlakna, parametrima oblika, konstantama prigušenja i brzini promjene duljine mišića. Sila koja se prenosi s mišića na tetivu, sila serijskog elementa SE, ovisi o duljini tetive, konstantama opružnog djelovanja tetiva i parametrima oblika [8]. Neke od ovih veličina moguće je pronaći u literaturi, no velik je broj potrebno mjeriti, što nije uvijek moguće i ponekad je potrebno koristiti pretpostavke i pojednostavljenja zbog kojih model gubi na točnosti.

Za razliku od biomehaničkih matematičkih modela, kod metoda koje nisu temeljene na modelu, poput umjetne neuronske mreže, nisu potrebne detaljne informacije kao što su matematički izrazi za odnos EMG signala i sile, ili kompletno razumijevanje bioloških fenomena u ljudskom mišićno-koštanom sustavu. Umjetne neuronske mreže mogu raditi s nelinearnošću koja se javlja u odnosu elektromiografskog signala i sile razvijene u mišiću.

## 2.2. Umjetne neuronske mreže

Umjetna neuronska mreža (Artificial Neural Network – ANN) pojednostavljene je prave, biološke mreže neurona. Cilj neuronskih mreža oponašanje je ljudske sposobnosti prilagođavanja promjeni okolnosti i okruženja. To značajno ovisi o sposobnosti učenja od događaja koji su se dogodili i sposobnosti korištenja stečenog znanja u budućim situacijama. [9]

Robert Hecht-Nielsen definira umjetnu neuronsku mrežu kao paralelnu distribuiranu informacijsku strukturu koja se sastoji od elemenata procesiranja, neurona, koji su povezani u slojeve jednosmjernim vezama. Neuroni imaju lokalnu memoriju i predstavljaju osnovnu jedinku procesiranja. [10]

Mreže poput ljudi uče prema primjeru. Konfiguriraju se za specifične aplikacije poput prepoznavanja uzoraka ili klasifikacije podataka kroz proces učenja. Učenje u biološkim sustavima uključuje podešavanje sinaptičkih veza između neurona. Isto se događa i kod neuronskih mreža. Dakle, mreža stječe znanje procesom učenja i jačine veza između neurona, odnosno sinaptičke težine, koriste se za spremanje znanja, te u ta dva aspekta umjetna neuronska mreža nalikuje na mozak. Organizacija i težine na vezama neurona određuju izlaz iz mreže.

Neuronske mreže koriste se iz želje da računalni sustav preuzme neke od poželjnih osobina ljudskog mozga kao što su:


- adaptivno učenje – sposobnost učenja iz podataka danih za treniranje mreže ili inicijalnog iskustva,
- samo-organizacija – mreža može stvoriti vlastitu organizaciju ili reprezentaciju informacija koje je dobila prilikom učenja,
- tolerancija kvarova ili grešaka - neke sposobnosti mreže mogu se očuvati i nakon velikog kvara mreža, može doći do smanjenja performansa,
- niska potrošnja energije,
- mogućnost generalizacije,
- rad u stvarnom vremenu.

Neuronske mreže su za razliku od konvencionalnih načina obrade podataka vrlo dobre u procjeni nelinearnih odnosa uzoraka, mogu raditi s nejasnim ili nepotpunim podacima, robusne

su na pogreške, prilagodljive okolini, sposobne steći znanje iz iskustva te mogu raditi s velikim brojem varijabli ili parametara. One rješavaju sve probleme kod kojih postoji odnos između ulaznih i izlaznih varijabli, bez obzira na visoku složenost i nelinearnost te veze. Uz korištenje u medicinske, strojarske, bankarske svrhe, najčešće se primjenjuju na zadatke poput raspoznavanja uzoraka, obrade slike ili govora, kod problema optimizacije, za nelinearno upravljanje, simulacije te obrade nekompletnih podataka.

Element procesiranja umjetne neuronske mreže analogan je biološkom neuronu, slika 7. Glavni elementi biološkog neurona su:

- dendriti – primaju signale s ostalih neurona,
- soma – zbraja sve nadolazeće signale,
- akson – kada stanica ispali signal njime se taj signal šalje drugim stanicama,
- sinapse – elektrokemijske veze između neurona.



**Slika 7. Biološki akson [11]**

Sinapse pretvaraju presinaptički električni signal u kemijski signal te kasnije ponovno u postsinaptički električni signal. Amplituda ulaznih impulsa modificira se parametrima sadržanima u sinapsama. Priroda modifikacije ovisi o tipu sinapse, koji može biti inhibicijski ili ekscitabilni. Postsinaptički signali se sakupljaju i šalju dendritima u tijelo živčane stanice. Soma generira izlazni signal koji putuje aksonom do sinapsa drugih neurona. Frekvenciju ispaljivanja neurona kontroliraju parametri sinapsa, tj. težine. [9]



Dijelovi umjetnog neurona bazirani na biološkom su:

- neuron = tijelo stanice,
- težine = dendriti,
- ulaz mreže = soma,
- izlaz mreže = akson.


Umjetna neuronska mreža okarakterizirana je arhitekturom mreže, težinama i aktivacijskom funkcijom. Raspored neurona u slojevima i uzorak veza unutar sloja i među slojevima naziva se arhitektura ili topologija mreže. Arhitekture dolaze u raznim oblicima i veličinama. Mreža se ponaša kao funkcija vektora vrijednosti koja uzima vektor na ulazu te na izlazu daje drugi vektor. Neke od arhitektura mreža su :

- unaprijedne jednoslojne mreže,
- unaprijedne višeslojne mreže,
- mreže s povratnom vezom,
- ljestvičaste mreže.

Postavljanje vrijednosti težina je ono što omogućava proces učenja ili treniranja. Proces modifikacije težina s ciljem ostvarivanja željenog izlaza zove se treniranje mreže. Unutarnji proces koji se odvija nakon treninga naziva se učenje. Vrste treniranja mreže su:

- pod nadzorom – mreži se daje serija ulaznih primjera te se izlaz mreže uspoređuje sa željenim izlazom. Proces se nastavlja sve dok mreža ne dođe do traženog izlaza. Težine u mreži podešavaju se prema algoritmu učenja. Neki od algoritama učenja pod nadzorom su Hebb-ova mreža, algoritam s povratnim postupkom (Back-propagation), itd.
- bez nadzora – za dani ulazni vektor nije poznat izlaz. Mreža modificira težine s ciljem da za slične ulaze izlaz bude isti. Proces je mnogo kompleksniji i teži za implementaciju od učenja pod nadzorom. Mreže bez nadzora još se nazivaju i samo-učene mreže ili samo-organizirajuće mreže zbog sposobnosti samo-učenja. Jedan od primjera su samo-organizirajuće mape značajki, u kojima proces treniranja promatra statistička svojstva seta za trening i slične vektore grupira u klase.
- potpomognuto – učitelj je prisutan, ali točan odgovor nije dan mreži. Mreži se daje do znanja je li izlazni odgovor točan ili kriv. Tom informacijom, mreža se modificira i poboljšava svoju uspješnost.

Skup podataka za učenje često se dijeli na tri dijela: skup za učenje, skup za testiranje i skup za validaciju mreže. Prvi skup služi za učenje, tj. podešavanje težina. Tijekom učenja vrši se provjera rada mreže s trenutnim težinama koristeći skup za testiranje, kako bi se postupak učenja zaustavio u slučaju degradacije performansi mreže. To se događa u slučaju pretreniranja mreže, tj. nakon određenog broja iteracija mreža gubi svojstvo generalizacije i izvrsno obrađuje podatke iz seta za učenje, ali loše radi s novim podacima [12]. Praćenjem izlaza iz mreže dobivenog od seta za testiranje moguće je otkriti iteraciju u kojoj dobiveni izlaz najmanje odstupa od traženog, slika 8. Skupom za validaciju provjerava se točnost i preciznost obrade podataka.

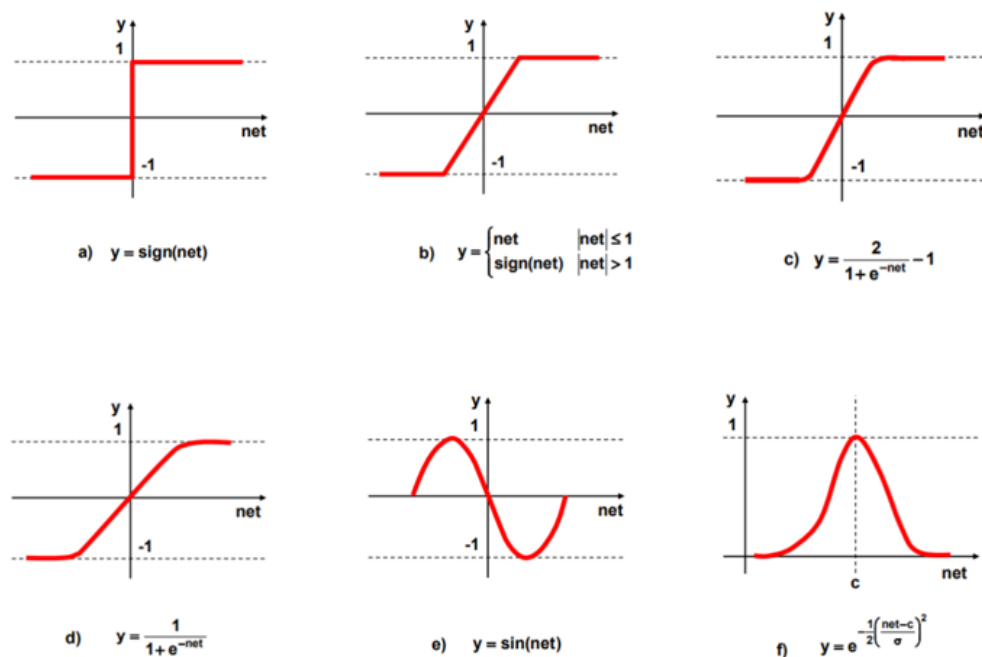


**Slika 8. Odstupanje izlaza kroz iteracije [12]**

Način učenja mreže dijeli se na:

- Pojedinačno učenje – u jednoj iteraciji korišten je samo jedan ulazni vektor, što znači da se nakon svakog uzorka vrši prilagodba težina.
- Učenje po skupu – u jednoj iteraciji korišten je skup ulaznih vektora, težine se podešavaju nakon što cjelokupni skup prođe kroz korak učenja.

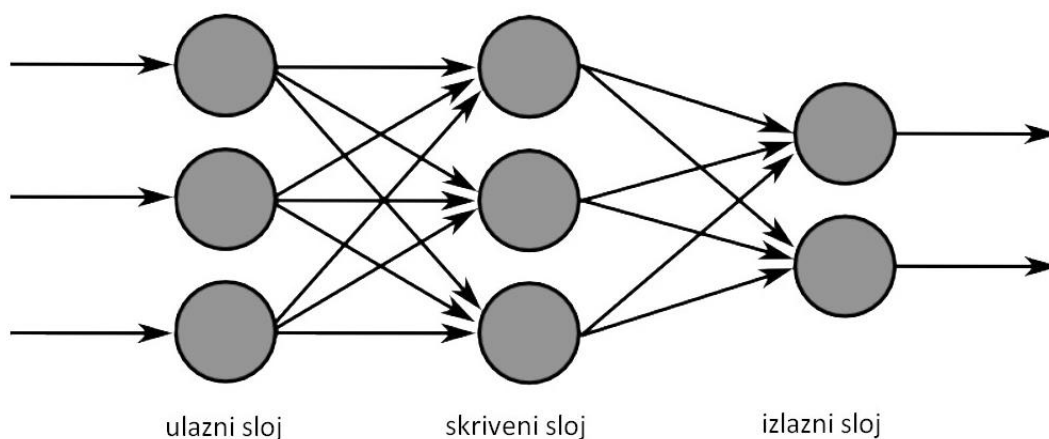
Aktivacijska funkcija izračunava izlazni odziv neurona. Na sumu ponderiranih ulaznih signala primjenjuje se aktivacija kako bi se dobio odziv. Za neurone u istom sloju koristi se ista aktivacijska funkcija. Te funkcije mogu biti linearne i nelinearne. Neke od tipičnih aktivacijskih funkcija prikazane su na slici 9.



Slika 9. Aktivacije funkcije [13]

### 2.2.1. Način rada neuronske mreže

Primjer višeslojne neuronske mreže vidljiv je na slici 10. i razjašnjen je prema literaturi [13].



Slika 10. Višeslojna neuronska mreža [14]

Tipična višeslojna neuronska mreža sastoji se od ulaznog sloja, izlaznog sloja i skrivenih slojeva neurona. Ulazni sloj vezan je sa skrivenim koji je povezan s izlaznim slojem. Ulazni

sloj neurona predstavlja neobrađene podatke koji ulaze u mrežu. Aktivnost neurona skrivenog sloja određena je aktivnostima ulaznog sloja i težinama na vezama ta dva sloja. Izračun funkcije sume za skriveni sloj prikazan je jednadžbom (2)

$$sum_{1j} = \sum_{i=0}^I v_{ji}x_i, \quad j = 1, 2, \dots, J-1 \quad i = 1, 2, \dots, I, \quad (2)$$

gdje  $\mathbf{x}$  predstavlja vektor ulaznih signala,  $\mathbf{v}$  težine veza ulaznog i skrivenog sloja,  $I$  broj ulaznih neurona te  $J$  broj neurona u skrivenom sloju plus bias ( $y_J = 1$ ).

Aktivacijska funkcija skrivenog sloja prikazana je jednadžbom (3)

$$s_j = \gamma_j(sum_{1j}), \quad j = 1, 2, \dots, J-1, \quad (3)$$

gdje je  $\gamma_j$  aktivacijska funkcija  $j$ -tog neurona skrivenog sloja, a  $s$  izlaz skrivenog sloja neurona. Slično tomu, ponašanje izlaznog sloja ovisi o aktivnosti neurona skrivenog sloja i težinama na vezama skrivenog i izlaznog sloja. Funkcija sume težina i izlaza skrivenog sloja prikazana je jednadžbom (4), a aktivacijska funkcija izlaznog sloja jednadžbom (5)

$$sum_{2k} = \sum_{j=0}^J w_{kj}s_j, \quad j = 1, 2, \dots, J \quad k = 1, 2, \dots, K, \quad (4)$$

$$Y_k = \gamma_k(sum_{2k}), \quad k = 1, 2, \dots, K, \quad (5)$$

gdje su težine veza skrivenog sloja s izlaznim predstavljene s  $\mathbf{w}$ ,  $\gamma_k$  je aktivacijska funkcija  $k$ -tog neurona izlaznog sloja,  $\mathbf{y}$  je vektor izlaznih podataka, a  $K$  broj neurona izlaznog sloja.

Prema razlici ostvarenog izlaza mreže i željenog izlaza izračunava se pogreška učenja. Određuje se globalna greška sumom kvadratne pogreške, jednadžba (6)

$$E = \frac{1}{2} \sum_{k=1}^K (y_k - y_{d_k})^2, \quad k = 1, 2, \dots, K, \quad (6)$$

gdje je  $\mathbf{y}_d$  željeni izlaz mreže, a  $\mathbf{y}$  dobiveni izlaz.

Prema pogrešci učenja adaptiraju se parametri učenja  $\vartheta$ , tj. težine  $\mathbf{v}$  i  $\mathbf{w}$ , prema izrazu (7)

$$\vartheta(m+1) = \vartheta(m) + \Delta\vartheta(m), \quad (7)$$

gdje je  $m$  promatrani korak učenja,  $\vartheta(m+1)$  nova vrijednost parametra učenja,  $\vartheta(m)$  trenutna vrijednost parametra učenja i  $\Delta\vartheta(m)$  veličina promjene parametra učenja. Pogrešku parametra učenja  $E(\vartheta)$  moguće je u blizini točke  $\vartheta$  aproksimirati s prva dva člana Taylorovog reda čime je dobiven gradijent pogreške prikazan jednadžbom (8)

$$\nabla E(\vartheta) = \frac{\partial E(\vartheta)}{\partial \vartheta}. \quad (8)$$

Za najveće moguće smanjenje pogreške potrebno je odrediti  $\Delta\vartheta$  za koji promjena pogreške parametara učenja poprima najveći negativan iznos, što se ostvaruje izrazom (9)

$$\Delta\vartheta = -\eta \nabla E(\vartheta) = -\eta \frac{\partial E(\vartheta)}{\partial \vartheta}, \quad (9)$$

gdje je  $\eta$  koeficijent brzine učenja koji je najčešće u rasponu  $10^{-4} - 10^{-1}$ .

Uvrštavanjem izraza (9) u (7) dobiven je algoritam povratnog prostiranja pogreške koji modificira težine u mreži, jednačba (10)

$$\vartheta(m+1) = \vartheta(m) - \eta \nabla E(\vartheta). \quad (10)$$

Primjenom izraza (10) na težine izlaznog i skrivenog sloja dobiveni su izrazi (11) i (12) koji prikazuju završnu fazu koraka učenja te nakon toga kreće unaprijedna faza sljedećeg koraka.

$$w_{kj}(m+1) = w_{kj}(m) - \eta \nabla E(\vartheta) = w_{kj}(m) + \eta \delta_{2k} s_j, \quad \delta_{2k} = y_{d_k} - y_k, \quad (11)$$

$$v_{ji}(m+1) = v_{ji}(m) - \eta \nabla E(\vartheta) = v_{ji}(m) + \frac{1}{2} \eta (1 - s_j^2) x_i \left( \sum_{k=1}^K \delta_{2k} w_{kj} \right). \quad (12)$$

### 3. RAZRADA ZADATKA


#### 3.1. Mjerenje elektromiografskog signala

Za mjerenje elektromiografskog signala odabran je Muscle SpikerShield Pro američke tvrtke Backyard Brains, slika 10. Izabran je zbog toga što se koristi uz Arduino mikrokontroler, koji ima integrirano razvojno okruženje (IDE) u kojemu ga je moguće po volji programirati. Prednost ovog senzora nad drugima koji se također mogu koristiti uz Arduino je što ima 6 ulaznih kanala, tj. moguće je istovremeno prikupljati signale sa 6 različitih mišića.



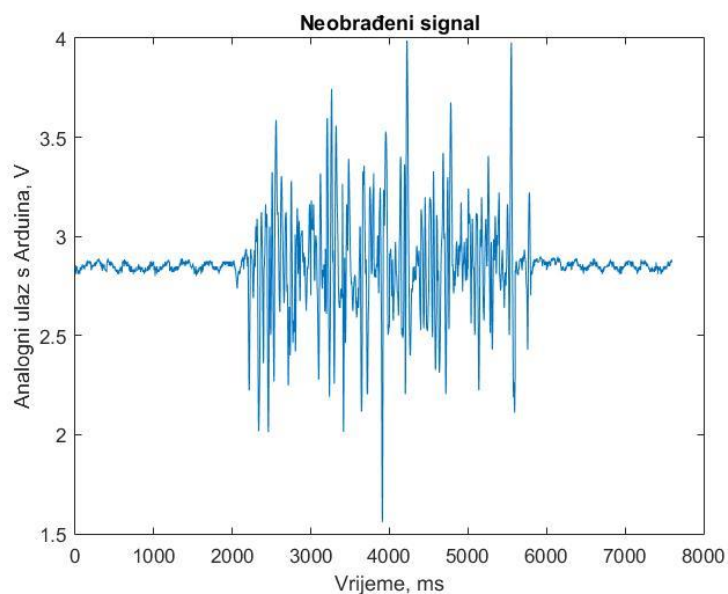
Slika 11. Muscle SpikerShield Pro [15]

Mjeren je EMG signal dvoglavog nadlaktičnog mišića (lat. musculus biceps brachii), slika 12. Korištene su jednokratne, gelirane Ag/AgCl elektrode. Jedna je postavljena na trbuh mišića, a druga otprilike 2 cm niže. Elektroda za uzemljenje postavljena je na zapešće ispitanika.

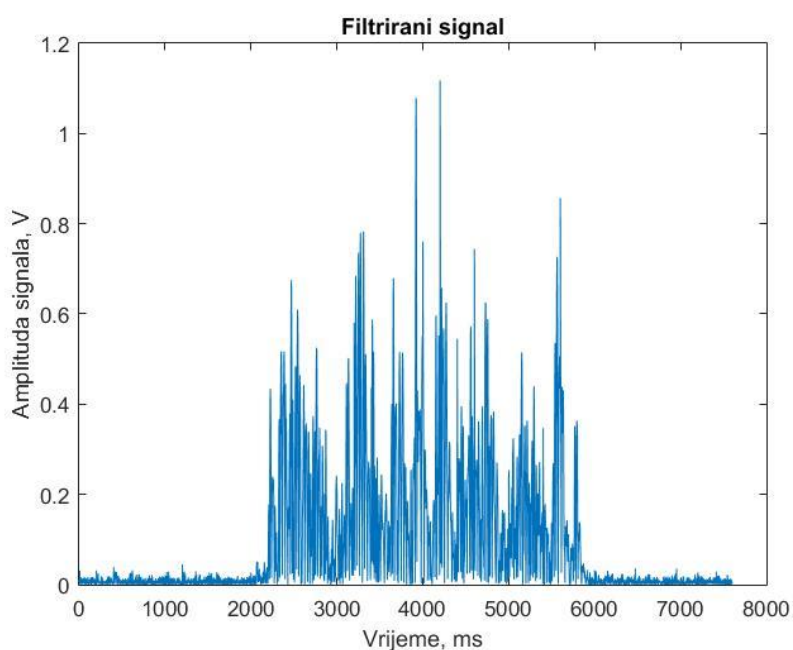


Slika 12. Dvoglavi nadlaktični mišić na koji su postavljene elektrode [16]

Signal uzorkovan frekvencijom od 1 kHz u senzoru prolazu kroz pojačala te je mjerena amplituda u rasponu 0 – 5 V. Na daljnju obradu poslan je u MATLAB (MATrix LABoratory), računalni softver za numeričko i matematičko računanje. Prije analize podataka, signal prolazi kroz pojasnu branu, Butterworth-ov filter 3. reda kako bi se odstranile smetnje mreže (oko 50 Hz), i visoko propusni filter, Butterworth-ov filter 4. reda, granične frekvencije 10 Hz, te se potom ispravlja.




**Slika 13. Neobrađeni signal koji Arduino šalje MATLAB-u**



**Slika 14. Filtriran i ispravljen signal**

Nakon ispravljanja, signal je filtriran nisko propusnim filterom, Butterworth-ovim filterom 4. reda s graničnom frekvencijom 10 Hz, kako bi se otklonili slučajni, neponovljivi pikovi visokih amplituda, odnosno kako bi se signal „izglačao“, slika 15.



Slika 15. EMG signal nakon filtriranja i usrednjavanja

### 3.2. Priprema podataka za učenje neuronske mreže

EMG signal sadrži mnogo suvišnih informacija i šuma. Stoga se iz njega izvlače značajke koje sadrže karakteristike signala i tvore vektorsku reprezentaciju mjerelog signala. Tri se vrste značajki koriste u sustavima upravljanja EMG-om: značajke vremenske domene, značajke frekvencijske domene te značajke vremensko-frekvencijske domene. Prema rezultatima radova velikog broja autora odabrane su sljedeće značajke:

- Srednja apsolutna vrijednost (Mean Absolute Value) – srednja vrijednost analiziranog segmenta prikazana je jednadžbom (13):

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i|, \quad (13)$$

gdje je N broj uzoraka u segmentu, a  $x_i$  predstavlja i-ti uzorak.



- Nagib srednje apsolutne vrijednosti (Mean Absolute Value Slope) – razlika između dvije srednje vrijednosti susjednih segmenata dana je izrazom (14):

$$MAVSLP_t = MAV_{t-1} - MAV_t. \quad (14)$$

- Duljina valnog oblika (Waveform length) – izraz (15) predstavlja mjeru amplitude, frekvencije i trajanja vala u signalu:

$$WL = \sum_{i=1}^{N-1} |x_{i+1} - x_i|. \quad (15)$$

- Jednostavni kvadratni integral (Simple Square Integral) – predstavlja energiju EMG signala prema izrazu prikazanom jednadžbom (16)

$$SSI = \sum_{i=1}^N |x_i|^2. \quad (16)$$

Vektor značajki računa se srednjom vrijednosti MAV-a, MAVSLP-a, WL-a i SSI-a na 200 uzoraka, tj. u funkciju ulazi 200 ms podataka koji se dijele na segmente po 40 uzoraka na kojima se računaju ranije navedene značajke te se uzima srednja vrijednost tih 5 segmenata.


Odabrane značajke pokazale su dobru razlučivost pri promjenama opterećenja primijenjenima na mišić od interesa, tablica 1. Stoga su izabrane za ulazni vektor neuronske mreže za estimaciju mišićne sile.

**Tablica 1. Normalizirane značajke EMG signala ovisno o opterećenju**

<b>Teret:</b>	0 kg	1 kg	2 kg	3 kg	4 kg	5 kg
<b>MAV</b>	0.0060	0.1101	0.1720	0.3460	0.7075	0.9151
<b>MAVSLP</b>	0.0124	0.1118	0.1596	0.2561	0.7042	0.6819
<b>WL</b>	0.0007	0.0185	0.0421	0.1488	0.5364	0.9102
<b>SSI</b>	0.0093	0.0903	0.1543	0.3573	0.6483	0.9686

Podaci za učenje mreže prikupljeni su snimanjem EMG signala prilikom podizanja tereta različitih masa (1 kg, 2 kg, 3 kg, 4 kg, 5 kg, bez opterećenja). U mjerenjima je sudjelovalo 5 ispitanika, te su podaci 4 ispitanika korišteni za učenje mreže, a jednog za testiranje. Za svako opterećenje snimanje je ponovljeno tri puta sa stankama kako ne bi došlo do zamora mišića.

Podaci se prikupljaju tijekom pridržavanja tereta u zadanom položaju, slika 16., u vremenskom trajanju od 6 sekundi. Iz snimaka su izdvojeni dijelovi u kojima se mišić kontrahira te su prikupljene značajke.



Slika 16. Položaj ruke tijekom prikupljanja značajki [17]

Uz značajke, zabilježene su i neke karakteristike ispitanika u svrhu usporedbe rezultata, prikazane u tablici 2.

Tablica 2. Karakteristike ispitanika

Ispitanik	1	2	3	4	5
Spol	Ž	Ž	Ž	M	M
Visina, [cm]	165	172	173	189	190
Težina, [kg]	51	62	60	95	110
Masa podlaktice $m_1$ , [kg]	0,893	1,085	1,05	1,777	2,057
Masa šake $m_2$ , [kg]	0,255	0,31	0,3	0,618	0,715
Duljina podlaktice $l_1$ , [cm]	23,5	25	25,5	34	35
Duljina podlaktice + centar šake $l_2$ , [cm]	29,5	31	32,5	42	44
Tjelesna aktivnost (1-česta, 2-umjerena, 3- slaba)	3	2	3	3	1
Lakoća podizanja tereta (1-lako, 2- umjereno teško, 3- teško)	2	3	3	1	1

Prema slici 16. postavljen je jednostavan model izračuna sile koju biceps mora proizvesti za pridržavanje tereta. Ruka je postavljena tako da su podlaktica i nadlaktica pod kutom od  $90^\circ$ . Model je važeći za stacionarno držanje tereta odnosno izometričku kontrakciju. Model je objašnjen jednadžbom (17)

$$F_b = \frac{m_1 g r_1 + (m_2 g + F_t) l_2}{d}, \quad (17)$$


gdje  $m_1$  predstavlja masu podlaktice,  $m_2$  masu šake,  $r_1$  udaljenost od centra mase podlaktice do lakta ( $l_1/2$ ),  $l_2$  udaljenost od centra mase šake do lakta,  $F_t$  silu tereta,  $d$  udaljenost bicepsa od lakatnog zloba i  $F_b$  silu razvijenu u mišiću.

Mase podlaktice i nadlaktice određene su u odnosu na ukupnu masu tijela, prema literaturi [18], tj. masa podlaktice je izražena kao 1,87% tjelesne mase za muškarce, 1,57% za žene, a masa šake kao 0,65% tjelesne mase za muškarce, a 0,5% za žene. Parametri duljine podlaktice i šake mjereni su izravno na ispitanicima, a za parametar  $d$  je pretpostavljeno da iznosi oko 4 cm.

Uvrštavanjem mase tereta, podataka duljina i masa ispitanika u jednadžbu (17) moguće je procijeniti koja je sila u bicepsu potrebna za pridržavanje tereta. Kod ispitanika veće težine i visine bit će razvijena veća sila u bicepsu u odnosu na onoga manje težine i visine prilikom pridržavanja istog tereta.

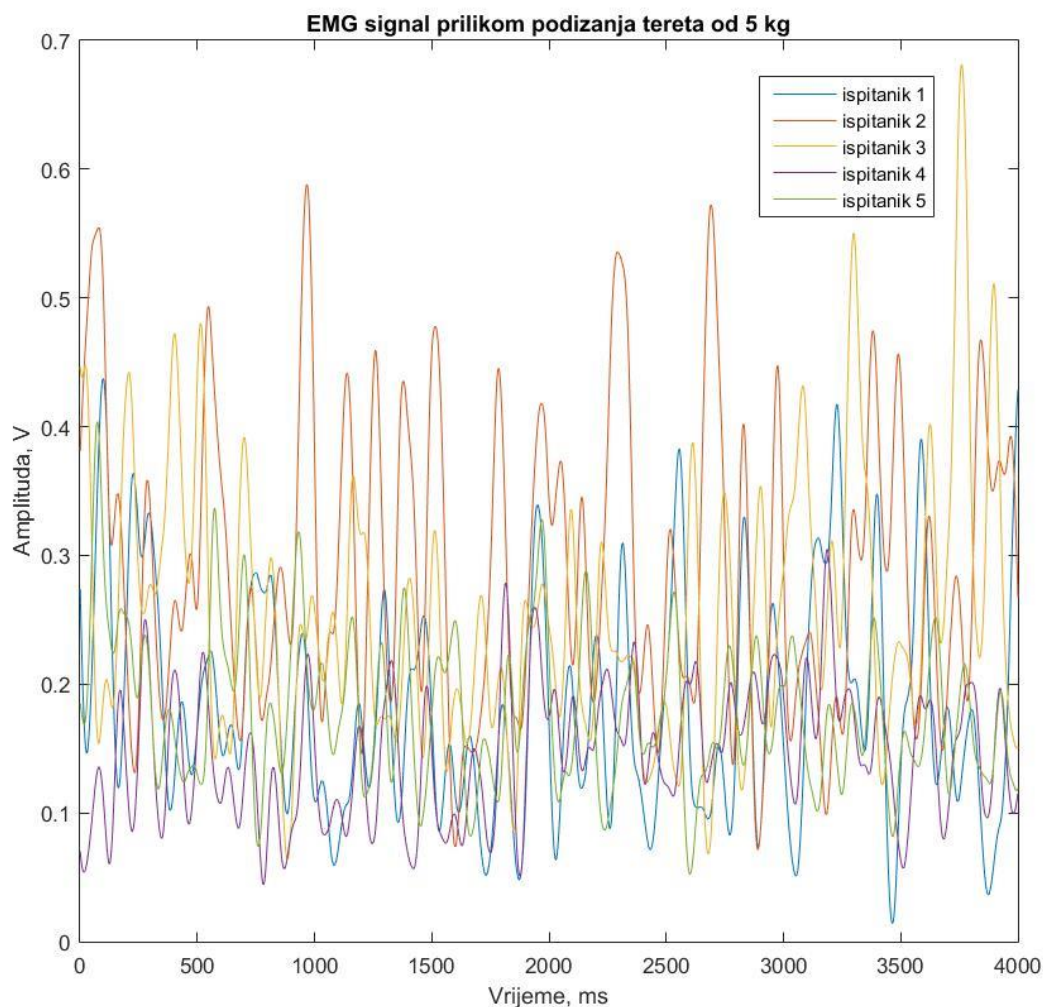
**Tablica 3. Procjena sile bicepsa za različita opterećenja**

	1	2	3	4	5
<b>Bez opterećenja</b>	44,2 N	56,8 N	56,7 N	137,7 N	165,4 N
<b>1 kg</b>	116,5 N	132,9 N	136,5 N	240,7 N	273,4 N
<b>2 kg</b>	188,7 N	208,9 N	216,2 N	343,7 N	381,3 N
<b>3 kg</b>	261,2 N	284,9 N	295,8 N	446,7 N	489,2 N
<b>4 kg</b>	333,6 N	360,9 N	375,6 N	549,7 N	597,1 N
<b>5 kg</b>	405,9 N	436,9 N	455,3 N	652,7 N	704,9 N



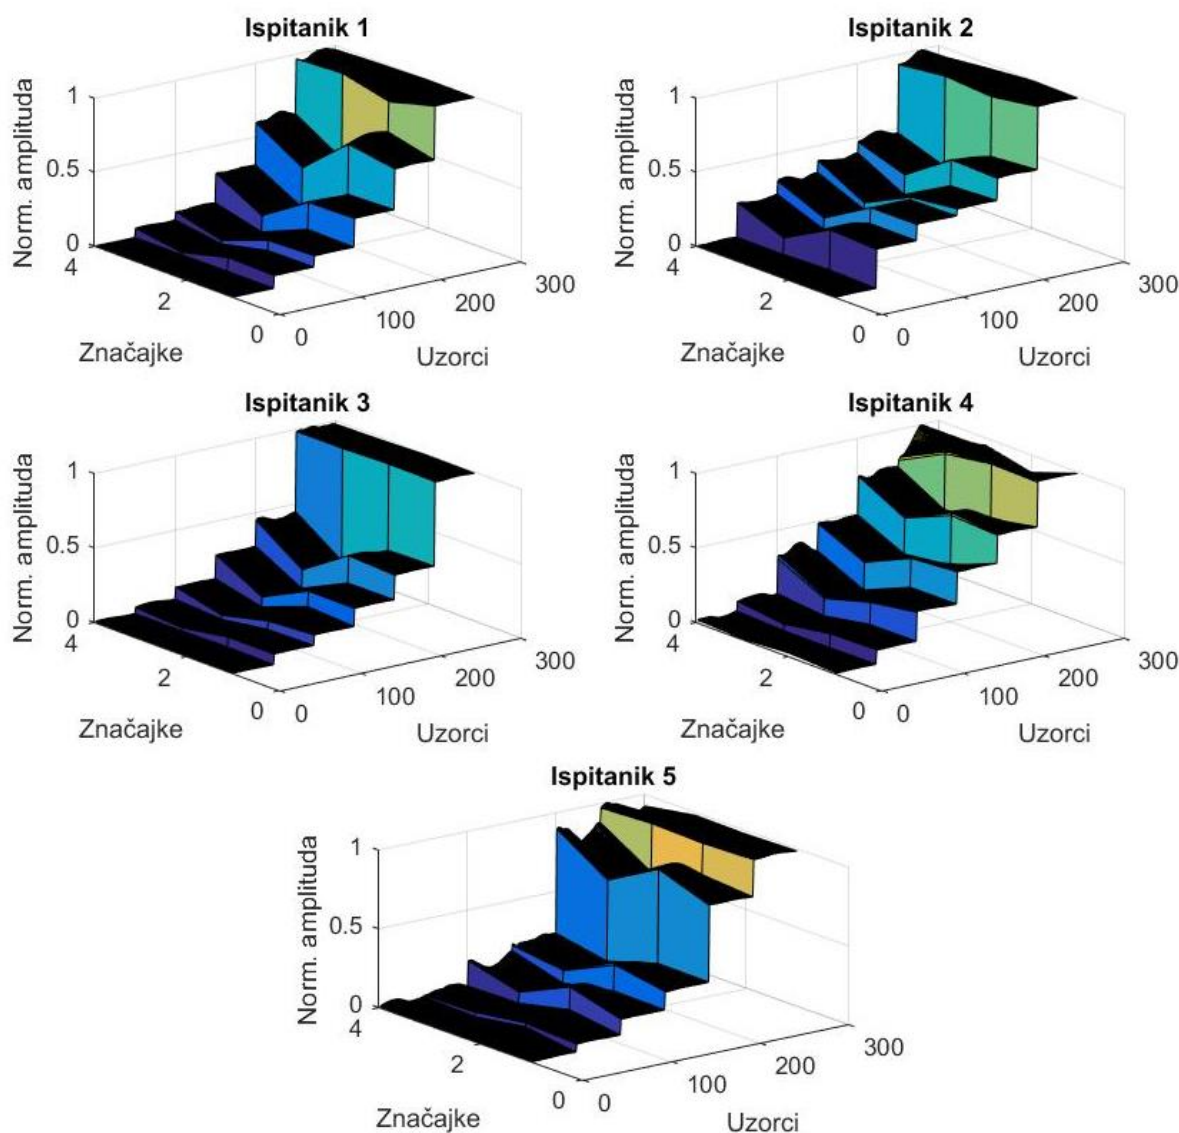
**Slika 17. Procjena sile razvijene u mišiću**

Suprotno tome, promatranjem izmjerenih EMG signala, slika 18., vidljiva je veća amplituda signala kod manjih ispitanika. To je moguće povezati i s karakteristikama ispitanika, kao što su učestalost tjelesne aktivnosti i lakoća podizanja tereta. Ispitanici 1, 2 i 3 su manje aktivni, žene i teže im je podići teret. Kod ispitanika 4 i 5 sila u bicepsu je veća, ali nije blizu maksimalnoj sili koju mišić može postići, kao što je to kod ispitanika 1, 2 i 3, što se očituje u manjoj aktivnosti mišića.



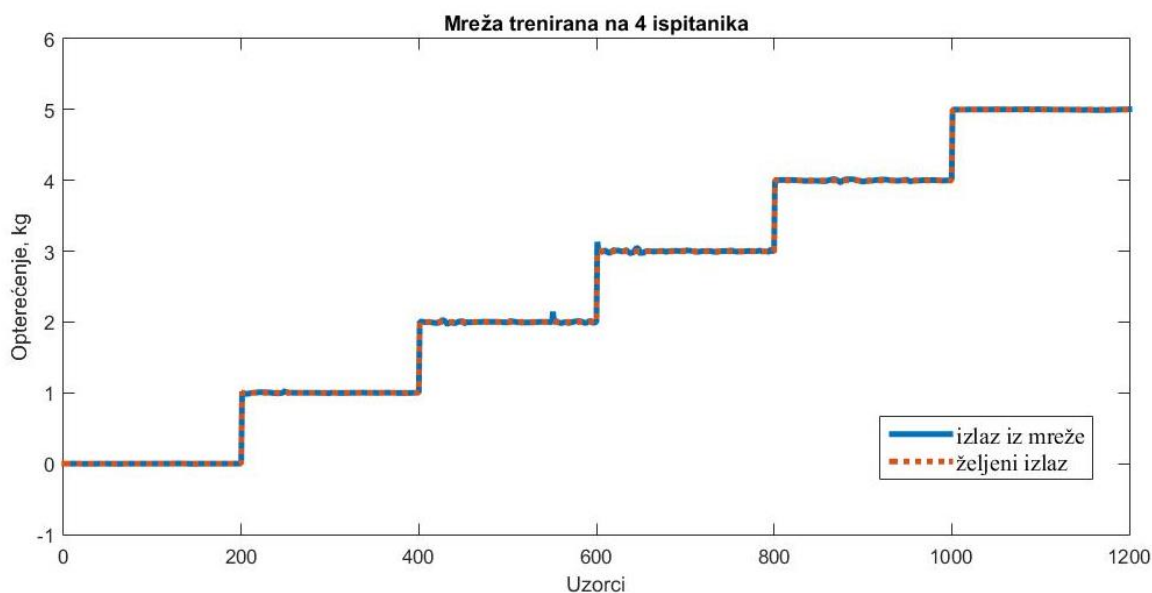
**Slika 18. Amplitude EMG signala kod ispitanika tijekom podizanja tereta od 5 kg**

U MATLAB-u je napravljena troslojna neuronska mreža s 4 neurona ulaznog sloja (značajke), 10 neurona skrivenog sloja i jednim neuronom izlaznog sloja. Mreža je trenirana skupom od 1200 vektora značajki, 50 vektora po svakom ispitaniku za svako opterećenje, i željenim izlaznim vektorom. Od toga je 840 (70%) vektora korišteno za treniranje mreže, 180 (10%) za testiranje i 180 (10%) za validaciju. Prije učenja mreže, skup uzoraka je normaliziran, slika 19., i, radi poboljšanja robusnosti i sposobnosti generalizacije mreže, izmiješan.



**Slika 19. Prikupljene značajke po ispitaniku**


Aktivacijska funkcija skrivenog sloja je tangens-sigmoidalna funkcija, a izlaznog sloja linearna funkcija. Algoritam učenja je Levenberg-Marquardt backpropagation, iterativan algoritam koji koristi Gauss-Newton-ov algoritam i metodu najstrmijeg pada kako bi dobio optimalno rješenje. Za ocjenu mreže koristi se srednja kvadratna pogreška (MSE), te je maksimalni broj iteracija 1000. Nakon učenja ocjena mreže iznosi oko  $2,48 \cdot 10^{-5}$ , a maksimalna greška 0,04. Za testiranje mreže podaci su posloženi od manjeg opterećenja prema većem te se za redom puštaju u mrežu, za svako opterećenje po 200 uzoraka. Po istom principu biti će prikazani svi odzivi u ovom radu.



**Slika 20. Dobiveni izlaz mreže u usporedbi sa željenim izlazom**

Nakon nekoliko provjera rada sustava s poznatim podacima izvršenih sa zadovoljavajućim uspjehom, napravljena je provjera na drugom ispitaniku kako bi se provjerila uspješnost generalizacije neuronske mreže.

Mreža je testirana na ispitaniku 5, čiji podaci nisu među podacima za učenje. Dobiveni izlaz razlikuje se od željenog izlaza. Maksimalni odmak traženog rješenja za uzorke bez opterećenja te prilikom podizanja tereta od 1 kg je -64%, a kod tereta od 2 kg -29%. Kod podizanja tereta od 3 kg mreža radi vrlo loše, te odstupanje iznosi čak +126% (kao da ispitanik podiže teret od 1 kg). Za teret od 4 kg mreža također ne daje zadovoljavajuće rezultate, odnosno odstupanje od željene vrijednosti je +0,23 kg. Za signale izmjerene prilikom podizanja tereta od 5 kg mreža radi zadovoljavajuće.



**Slika 21. Testiranje mreže na novom ispitaniku**

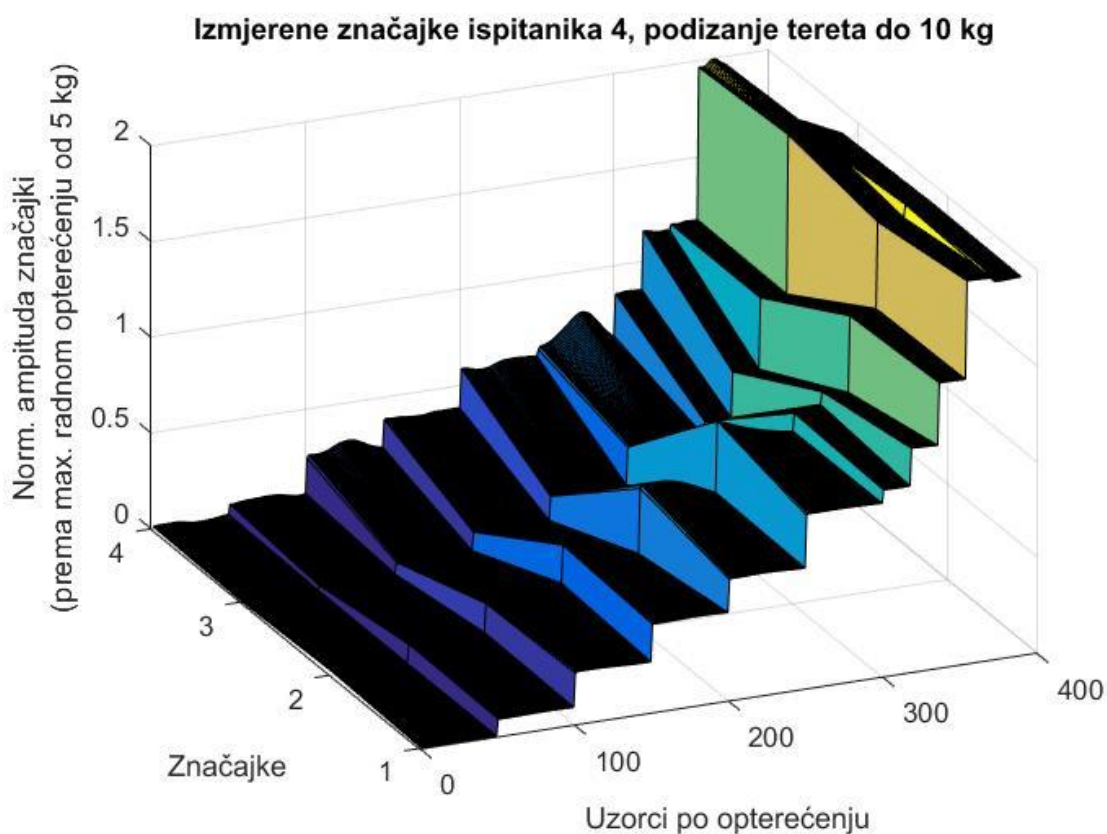
Nakon nezadovoljavajućeg testiranja mreže napravljene su preinake u modelu neuronske mreže, kao što su promjena broja skrivenih slojeva, promjena broja neurona u skrivenom sloju, itd., ali odziv nakon testiranja s novim podacima nije pokazao poboljšanja.

### 3.3. Analiza rada neuronske mreže i problema značajki signala

Ako se uspoređi izlaz iz mreže na slici 21. sa značajkama na slici 19. i podacima iz tablice 2. moguće je donijeti pretpostavku zašto sustav ne radi. Ispitanik 5 sklon je teškim tjelesnim naprezanjima, mišić za manja opterećenja daje otprilike jednaku elektromiografsku aktivnost kao da nije opterećen. Kod ispitanika 4 značajke su najbolje raspodijeljene jer mišiću nije niti teško niti lako podići teret. Kod ispitanika 1, 2 i 3 javlja se skok u amplitudi značajki prilikom podizanja tereta od 4 ili 5 kg, ovisno o ispitaniku, Pitanje je, je li razlog tomu opterećenje koje se približava maksimalnoj sili koju mišić može podnijeti, tj. najvećoj mogućoj kontrakciji mišića, i hoće li se sličan skok pojaviti kod ispitanika 4 i 5 prilikom podizanja viših opterećenja. Na ispitaniku 4 izvršena su mjerenja s teretom do težine 10 kg. Prikaz značajki dobivenih mjerenjem nalazi se na slici 22. Na slici se vidi veći skok amplituda značajki dobivenih mjerenjem podizanja tereta od 8 kg, te još veći skok kod tereta od 9 kg. Amplitude značajki za opterećenje od 10 kg jednake su i/ili nešto manje od amplituda za 9 kg, ovisno o značajki. Time se može zaključiti da se skok u amplitudi javlja u blizini maksimalnog opterećenja koje mišić




može izdržati, u slučaju ispitanika 4 to je teret od 9 kg. Nakon maksimalne amplitude, tj. maksimalnog mogućeg opterećenja, amplitude značajki ostaju iste ili se smanjuju, odnosno mišić ne izvršava radnju (ruka ne može pridržavati teret, već klone).



**Slika 22. Značajke signala ispitanika 4 kod mjerenja opterećenja do 10 kg**

Jedna od ideja za rješavanja problema rada mreže s nepoznatim podacima je dodatno treniranje mreže s djelomičnim podacima ispitanika čiji podaci nisu bili uključeni u učenje mreže. Npr. ranije spomenutoj neuronskoj mreži učenoj na podacima ispitanika 1, 2, 3 i 4 dodaju se podaci izmjereni podizanjem tereta od 1 i 3 kg ispitanika 5, koji najviše odudaraju od tražene krivulje, slika 21., i smanjen je broj neurona skrivenog sloja za bolju sposobnost generalizacije podataka. Odziv dobiven ovim rješenjem očekivano je bolji u područjima opterećenja čiji su podaci dani mreži za trening. Ali izlaz mreže dobiven iz podataka koji nisu poznati još više odstupa od traženog nego u slučaju kada nije bilo dodatnog učenja, slika 23. Do odstupanja dolazi zbog pretreniranja neuronske mreže, te ona radi zadovoljavajuće samo na naučenim podacima.




**Slika 23. Dotrenirana neuronska mreža**

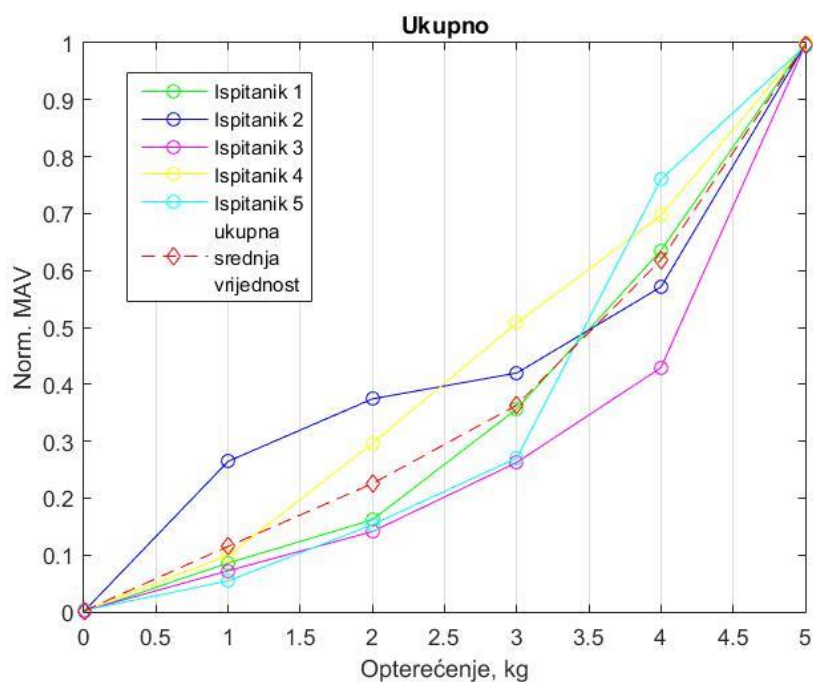
Zbog toga je napravljena analiza podataka koji ulaze u neuronsku mrežu, tj. razlika i odnosa amplituda značajki među ispitanicima.

Slika 24. prikazuje srednje apsolutne vrijednosti elektromiografskog signala tijekom podizanja tereta normalizirane prema maksimalnoj vrijednosti. Na slici je vidljivo da se vrijednosti prve značajke nalaze u rasponu  $0 - 4,9 \cdot 10^{-3}$  kod signala snimanog prilikom izvršavanja zadane radnje bez opterećenja. Raspon u kojem se nalaze vrijednosti kod podizanja tereta 1 – 4 kg je veći. Vrijednosti MAV-a za opterećenje od 1 kg su u rasponu od 0,07 do 0,26, za opterećenje od 2 kg minimalna vrijednost je 0,13, a maksimalna 0,38. Kod podizanja tereta od 3 kg minimalne vrijednosti značajki javljaju se kod ispitanika 3, u iznosu od 0,26, dok se kod ispitanika 4 javljaju najviše amplitude od 0,51 normaliziranog iznosa. Raspon kod tereta od 4 kg iznosi 0,43 – 0,7. Kod maksimalnog opterećenja primijećen je trend sličan vrijednostima prikupljenima za vrijeme testiranja bez opterećenja, tj. vrijednosti MAV-a su u vrlo malom rasponu, 0,99 – 1. Kod mjerenja u kojima ne dolazi do rasipanja vrijednosti neuronska mreža radi zadovoljavajuće. Problemi se javljaju tamo gdje se rasponi opterećenja preklapaju. Dakle, 20% značajki, koje su izmjerene za opterećenje od 1 kg, unutar su područja značajki za 2 kg i 3 kg, što je označeno tamno narančastom bojom u tablici 4. jer se amplitude značajke miješaju s dva područja kojima nužno ne pripadaju. Slično tome, 60% vrijednost dobivenih mjerenjem opterećenja od 2 kg ulazi u područje mjerenja od 1 kilograma, a 40% ulazi u područje od 3 kg. Što znači da za niti jednu vrijednost mjerenu za opterećenje od 2 kg nije moguće dokazati da pripada tome području. 20% vrijednosti za 3 kilograma preklapa se s mjerenjima za 1 kg, označeno tamno plavom bojom u tablici 4., 60% ulazi u područje od 2 kg, dok je 20% u

području za 4 kg, u tablici 4. označeno svijetlo plavom bojom. Kod mjerenja opterećenja od 4 kg 20% izmjerenih vrijednosti preklapa se s mjerenjima za 3 kg. Slika 25. daje detaljniji prikaz srednjih vrijednosti značajki i njihovih odnosa. Brojčani iznosi podataka prikazani su na tablici 4.



**Slika 24. Iznosi srednje apsolutne vrijednosti za različita opterećenja po ispitanicima**



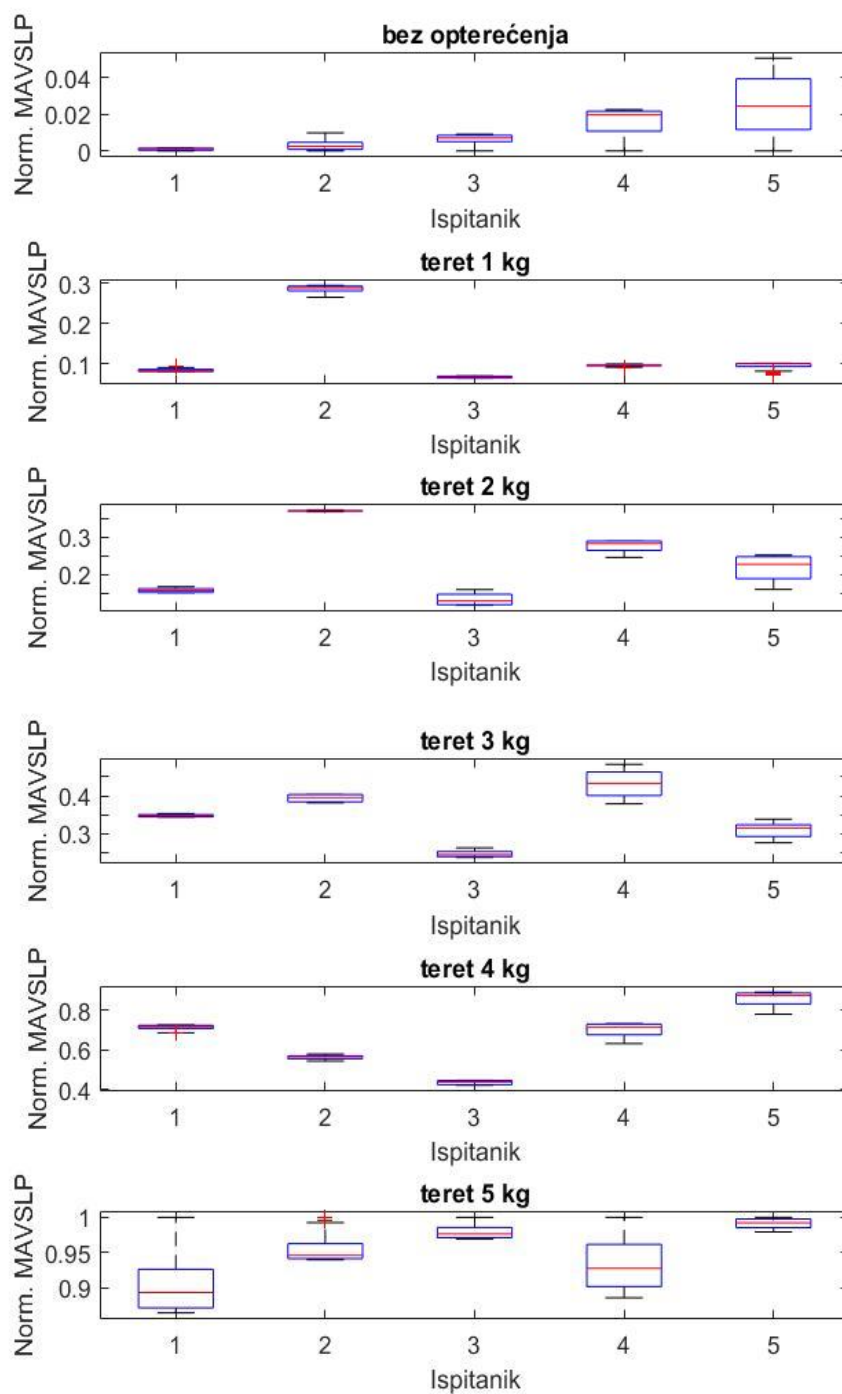
Slika 25. Usporedba srednjih vrijednosti prve značajke za sve slučajeve

Tablica 4. Iznosi srednje apsolutne vrijednosti EMG signala više ispitanika


Opterećenje		Ispitanik 1	Ispitanik 2	Ispitanik 3	Ispitanik 4	Ispitanik 5
Bez opterećenja	min.	0,000	0,000	0,000	0,000	0,0000
	sred. vr.	0,0002	0,0008	0,0019	0,0030	0,0026
	max.	0,0004	0,0016	0,0029	0,0042	0,0049
1 kg	min.	0,0849	0,2635	0,0703	0,0968	0,0528
	sred. vr.	0,0859	0,2647	0,0723	0,0989	0,0545
	max.	0,0863	0,2652	0,0734	0,1004	0,0563
2 kg	min.	0,1602	0,3727	0,1395	0,2909	0,1517
	sred. vr.	0,1619	0,3744	0,1412	0,2961	0,1532
	max.	0,1628	0,3755	0,1421	0,3002	0,1540
3 kg	min.	0,3548	0,4176	0,2604	0,5053	0,2657
	sred. vr.	0,3566	0,4197	0,2627	0,5076	0,2702
	max.	0,3572	0,4209	0,2643	0,5096	0,2720
4 kg	min.	0,6301	0,5670	0,4257	0,6914	0,7543

	sred. vr.	0,6354	0,5711	0,4292	0,6968	0,7599
	max.	0,6392	0,5745	0,4311	0,7	0,7624
5 kg	min.	0,9971	0,9932	0,9925	0,9911	0,9877
	sred. vr.	0,9989	0,9969	0,9965	0,9982	0,9945
	max.	1,000	1,000	1,000	1,000	1,0000

Na slici 26. prikazani su normalizirani iznosi nagiba srednje apsolutne vrijednosti za pet ispitanika, odnos i raspon njihovih amplituda. Kao i kod prve značajke zamjetna su preklapanja područja amplituda nagiba. Kod tereta od 1 kg, amplitude 20% nagiba preklapaju se s područjima opterećenja od 2 i 3 kg. 80% vrijednosti izmjerenih podizanjem tereta od 2 kg ulaze u područje 1 kg, dok je 48,4% istih moguće pogrešno protumačiti kao amplitude kod mjerenja opterećenja od 3 kg. 60% amplituda nagiba izmjerenim pod opterećenjem od 3 kg preklapa se s amplitudnim područjem za 2 kg, a 12% s područjem za 4 kg. Tako se i 20% vrijednosti u području koje obuhvaća amplitude izmjerene podizanjem 4 kg podudara s amplitudama vrijednosti mjerenih podizanjem 3 kg, te se čak i vrlo mali dio od 6,4% preklapa s područjem amplituda nagiba izmjerenih tijekom maksimalnog opterećenja. Vrijednosti su prikazane u tablici 5., a pregled srednjih vrijednosti druge značajke svih ispitanika na slici 27.



Slika 26. Iznosi nagiba srednje apsolutne vrijednosti signala za različita opterećenja po ispitanicima



**Slika 27. Usporedba srednjih vrijednosti druge značajke za sve slučajeve**


**Tablica 5. Iznosi nagiba srednje apsolutne vrijednosti EMG signala više ispitanika**

Opterećenje		Ispitanik 1	Ispitanik 2	Ispitanik 3	Ispitanik 4	Ispitanik 5
Bez opterećenja	min.	0,000	0,000	0,000	0,000	0,0000
	sred. vr.	0,0011	0,0031	0,0064	0,0159	0,0251
	max.	0,0018	0,0098	0,0091	0,0224	0,0504
1 kg	min.	0,0807	0,2654	0,0645	0,0901	0,0716
	sred. vr.	0,0842	0,2860	0,0673	0,0963	0,0959
	max.	0,0951	0,2948	0,0702	0,0999	0,1017
2 kg	min.	0,1508	0,3670	0,1177	0,2454	0,1601
	sred. vr.	0,1574	0,3695	0,1335	0,2759	0,2176
	max.	0,1674	0,3721	0,1598	0,2893	0,2515
3 kg	min.	0,3439	0,3821	0,2377	0,3791	0,2762
	sred. vr.	0,3480	0,3943	0,2466	0,4321	0,3087
	max.	0,3535	0,4043	0,2631	0,4834	0,3389
4 kg	min.	0,6844	0,5435	0,4201	0,6322	0,7816


	sred. vr.	0,7150	0,5627	0,4341	0,7024	0,8596
	max.	0,7271	0,5788	0,4449	0,7337	0,8934
5 kg	min.	0,8642	0,9397	0,9692	0,8859	0,9792
	sred. vr.	0,9049	0,9541	0,9792	0,9330	0,9913
	max.	1,0000	1,0000	1,0000	1,0000	1,0000

Normalizirane amplitude duljina valnog oblika prikazane su na slici 28., a usporedba njihovih vrijednosti prema opterećenju i srednjoj vrijednosti na slici 29. Također dolazi do preklapanja vrijednosti amplituda u područjima 1, 2, 3 i 4 kg, što je brojčano potkrijepljeno tablicom 6.





Slika 28. Iznosi duljine valnog oblika signala za različita opterećenja po ispitanicima




Slika 29. Usporedba srednjih vrijednosti treće značajke za sve slučajeve

Tablica 6. Iznosi duljina valnog oblika EMG signala više ispitanika


Opterećenje		Ispitanik 1	Ispitanik 2	Ispitanik 3	Ispitanik 4	Ispitanik 5
Bez opterećenja	min.	0,0000	0,0000	0,0000	0,0000	0,0000
	sred. vr.	0,0000	0,0003	0,0006	0,0012	0,0004
	max.	0,0000	0,0006	0,0010	0,0019	0,0008
1 kg	min.	0,0132	0,1117	0,0180	0,0414	0,0260
	sred. vr.	0,0134	0,1127	0,0187	0,0426	0,0281
	max.	0,0135	0,1137	0,0191	0,0435	0,0303
2 kg	min.	0,0352	0,1872	0,0436	0,1563	0,0914
	sred. vr.	0,0358	0,1882	0,0443	0,1633	0,0938
	max.	0,0362	0,1889	0,0448	0,1676	0,0959
3 kg	min.	0,1449	0,2294	0,1089	0,3401	0,1723
	sred. vr.	0,1457	0,2302	0,1106	0,3409	0,1765
	max.	0,1461	0,2316	0,1120	0,3414	0,1797
4 kg	min.	0,4097	0,3624	0,2331	0,5776	0,6846

	sred. vr.	0,4204	0,3700	0,2343	0,5811	0,6933
	max.	0,4298	0,3764	0,2355	0,5847	0,6983
5 kg	min.	0,9899	0,9715	0,9844	0,9536	0,9851
	sred. vr.	0,9952	0,9854	0,9925	0,9813	0,9935
	max.	1,0000	1,0000	1,0000	1,0000	1,0000

Amplitude normalizirane vrijednosti jednostavnog kvadratnog integrala, tj. energije elektromiografskog signala, prikazane su slikom 30., s usporedbama vrijednosti na slici 31. Ponovno je moguće primijetiti da amplitude mjerenja za vrijeme podizanja tereta od 1 kg ulaze u područje amplituda od 2 kg, amplitude mjerenja kod podizanja tereta od 2 kg preklapaju se s amplitudnim područjima od 1 i 3 kg. Isto tako, vrijednosti amplituda za opterećenje od 3 kg moguće je pronaći i kod opterećenja od 2 i 4 kg, a dio vrijednosti izmjerenih pod teretom od 4 kg zahvaća amplitude izmjerene prilikom opterećenja od 3 kg te čak i malim dijelom onih izmjerenih za maksimalno opterećenje od 5 kg.



Slika 30. Iznosi energije signala za različita opterećenja po ispitanicima



Slika 31. Usporedba srednjih vrijednosti četvrte značajke za sve slučajeve

Tablica 7. Iznosi energije EMG signala više ispitanika

Opterećenje		Ispitanik 1	Ispitanik 2	Ispitanik 3	Ispitanik 4	Ispitanik 4
Bez opterećenja	min.	0,0000	0,0000	0,0000	0,0000	0,0000
	sred. vr.	0,0004	0,0042	0,0043	0,0110	0,0159
	max.	0,0010	0,0084	0,0084	0,0193	0,0320
1 kg	min.	0,0572	0,2159	0,0396	0,0718	0,0181
	sred. vr.	0,0617	0,2247	0,0474	0,0887	0,0361
	max.	0,0658	0,2369	0,0534	0,0991	0,0502
2 kg	min.	0,1134	0,2987	0,1179	0,3053	0,1094
	sred. vr.	0,1191	0,3206	0,1199	0,3482	0,1448
	max.	0,1241	0,3373	0,1222	0,3868	0,1879
3 kg	min.	0,3110	0,3753	0,2736	0,4785	0,2130
	sred. vr.	0,3157	0,3884	0,2760	0,4865	0,2325
	max.	0,3198	0,4031	0,2789	0,4939	0,2489
4 kg	min.	0,6008	0,4696	0,4255	0,7243	0,7884

	sred. vr.	0,6177	0,4927	0,4428	0,7481	0,8523
	max.	0,6406	0,5143	0,4633	0,7646	0,9083
5 kg	min.	0,9558	0,9347	0,9816	0,7954	0,9007
	sred. vr.	0,9808	0,9643	0,9906	0,9012	0,9518
	max.	1,0000	1,0000	1,0000	1,0000	1,0000


Iz prikazanog dubljeg pogleda na amplitude značajki moguće je zaključiti da neuronska mreža ne radi zadovoljavajuće jer podaci kojima je učena i na kojima je testirana nisu jednoznačni. Mreža radi prividno zadovoljavajuće s naučenim podacima, ali samo zato što je pretrenirana, tj. došlo je do slaganja veza u algoritmu među podacima, no te veze za bilo kakav novi, nepoznati slučaj daju besmislene odgovore.

### 3.4. Drugi pristup –neuronska mreža jednog ispitanika

U prošlom poglavlju prikazano je da zadovoljavajući rad neuronske mreže za procjenu sile mišića nije moguć kada se koriste podaci više ispitanika, zbog različitih nepredvidivih amplitudnih karakteristika značajki koje utječu na višeznačnost podataka u mreži.

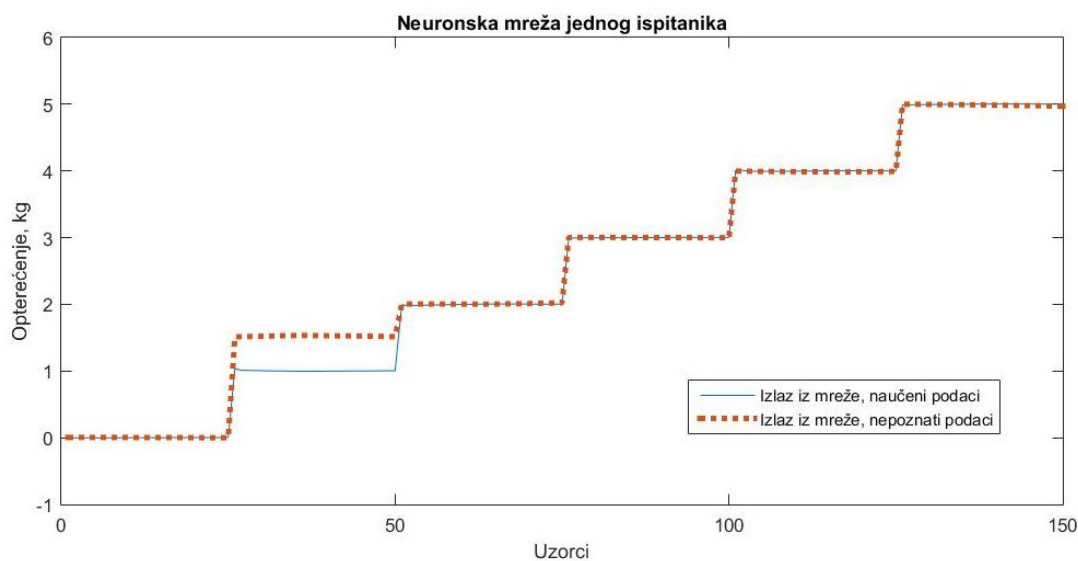
No, kao što je rečeno u poglavlju 3.2., razlike u amplitudama značajki dobivenih mjerenjem elektromiografskog signala mišića pod različitim opterećenjima su vidljive. Stoga, kako bi se izbjegli višeznačni podaci, napravljena je neuronska mreža korištenjem podataka samo jednog ispitanika.

Prva mreža trenirana je s pola uzoraka značajki izmjenjenih pod svim opterećenjima, tj. korišteno je 25 od 50 vektora značajki po svakom opterećenju odnosno ukupno 150 ulaznih vektora. Broj neurona skrivenog sloja postavljen je na 2, odabran je što manji broj za bolju sposobnost generalizacije i veću brzinu rada, te je pokazao dobre performanse. Dobiveni izlazi iz neuronske mreže prikazani su na slici 32.



**Slika 32. Neuronska mreža na podacima jednog ispitanika, naučeni i nepoznati podaci od istog mjerenja**


Zatim su umjesto podataka za podizanje tereta od 1 kg neuronskog mreži dani podaci pri podizanju tereta od 1.5 kg. Prikaz dobivenog odziva mreže nalazi se na slici 33. Mreža estimira podignuti teret za nepoznate podatke s maksimalnom greškom od 0.018 kg.



**Slika 33. Neuronska mreža jednog ispitanika testirana na nepoznatim podacima**

Nakon toga, napravljena je druga mreža kako bi se ispitala mogućnost odbacivanja određenog broja mjerenja prilikom postavljanja sustava. Podaci za učenje u ovom slučaju ne sadrže niti jedan vektor značajki s podacima izmjerenima prilikom opterećenja mišića teretom od 4 kg. Broj neurona skrivenog sloja ostao je isti. Dobiveni izlaz iz mreže za nepoznate podatke mjerenja opterećenja od 4 kg estimirao je opterećenje s greškom od 0.24 kg. Dakle postoji


greška, no manja je od odstupanja izlaza neuronske mreže trenirane na podacima više ispitanika. Usporedba izlaza iz mreže dobivenog iz mreži poznatih podataka i izlaza iz mreže dobivenog iz podataka u kojima se nalaze i mreži nepoznata mjerenja podizanja tereta od 4 kg prikazana je na slici 34.



**Slika 34. Druga neuronska mreža jednog ispitanika, podaci tijekom opterećenja od 4 kg nepoznati mreži**

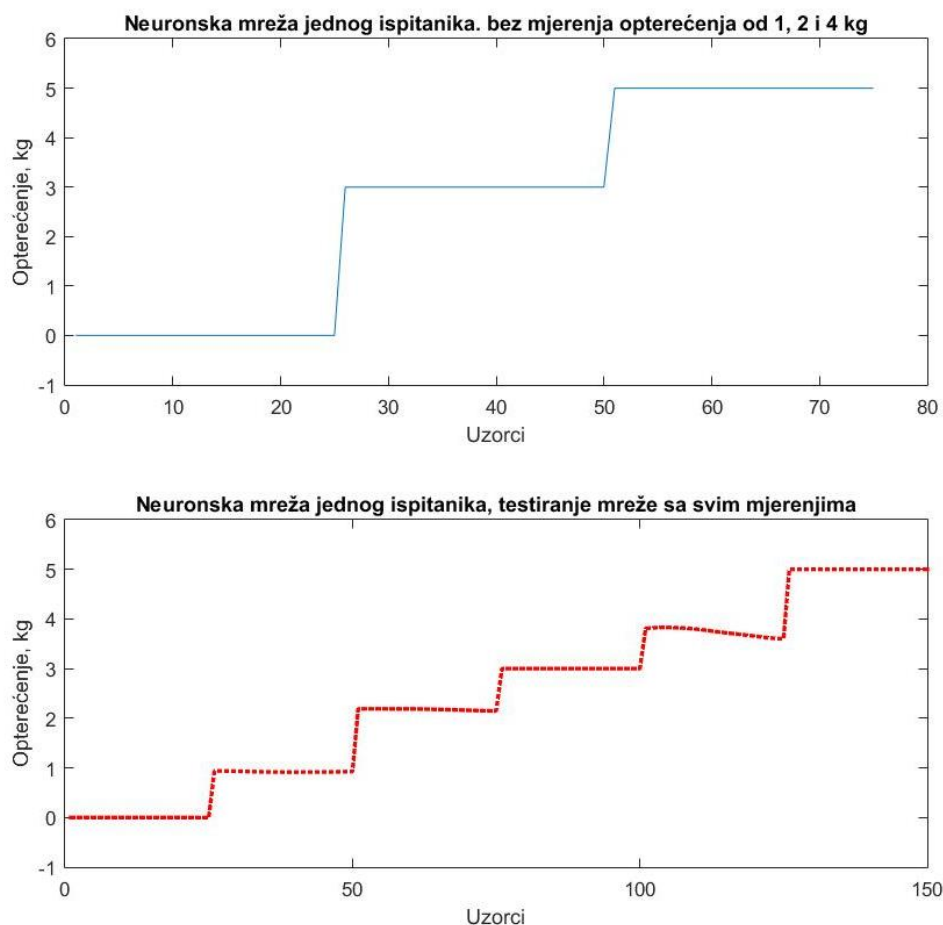
Napravljena je i mreža koja nije učena na podacima za opterećenja od 2 i 4 kg te je njen odziv prikazan na slici 35. Maksimalna greška izlaza kod ove mreže za opterećenje od 2 kg je 0.27 kg, a maksimalno odstupanje izlaza mreže za opterećenja od 4 kg iznosi 0.07 kg. Učenje i testiranje mreže, kako bi se potvrdili zadovoljavajući odzivi, ponovljeno je nekoliko puta zbog nasumičnog rada algoritma neuronske mreže, no u više navrata ponovljeni su rezultati s relativno malim odstupanjima željenog izlaza od dobivenog.






**Slika 35. Treća neuronska mreža jednog ispitanika, podaci tijekom opterećenja od 2 i 4 kg nepoznati mreži**

Isprobana je i četvrta neuronska mreža, učena podacima mjerenja opterećenja 0, 3 i 5 kg. Odstupanja dobivenog izlaza ove mreže od traženog nešto su veća. Odstupanje za željeni izlaz od 1 kg iznosi 0,08 kg, kod željenog opterećenja od 2 kg odstupanje ne prelazi 0,26 kg, a kod tereta od 4 kg maksimalno odstupanje iznosi 0,45 kg. Odzivi mreže prema naučenim podacima i prema nepoznatim podacima prikazani su na slici 36.



**Slika 36. Četvrta neuronska mreža jednog ispitanika, podaci tijekom opterećenja od 1, 2 i 4 kg nepoznati mreži**

Kod neuronske mreže trenirane bez graničnih podataka, tj. ulaznih vektora značajki dobivenih mjerenjem signala kada nema opterećenje odnosno prilikom maksimalnog opterećenja, odstupanja željenog izlaza od dobivenog nije zadovoljavajuće. Kod željenog odziva od 0 kg maksimalno odstupanje je 0.23 kg, dok je traženi izlaz za 5 kg potpuno krivo estimiran, jednak je izlazu od 4 kg, tj. odstupanje je konstantno i iznosi 1 kg, slika 37.



**Slika 37. Peta neuronska mreža jednog ispitanika, podaci tijekom opterećenja od 5 kg i bez opterećenja nepoznati mreži**

Iz prikazanih primjera neuronskih mreža moguće je zaključiti da će sustav funkcionirati uz manja odstupanja ukoliko je mreža trenirana i korištena na samo jednoj osobi. Prije korištenja neuronske mreže potrebno ju je istrenirati podacima za podešavanje sustava. Za bolju preciznost bilo bi dobro izvršiti mjerenja sa svih pet opterećenja i mjerenje bez opterećenja te ih sve uvrstiti među podatke za učenje, no sustav radi s određenim odstupanjem i s manjim brojem kalibracijskih mjerenja. U tablici 8. prikazana su odstupanja dobivenih izlaza iz neuronske mreže od željenih izlaza. Slučaj 1 odnosi se na mrežu treniranu djelomičnim podacima prikupljenima mjerenjem svih opterećenja, u slučaju dva navedena mreža testirana je nepoznatim mjerenjem od 1,5 kg. U slučaju 3 u skupu za učenje ne nalaze se podaci mjerenja prilikom opterećenja od 4 kg, odnosno u slučaju 4 podaci mjerenja pod opterećenjem od 2 i 4 kg, a testirane su podacima svih mjerenja. Minimalan broj mjerenja korišten je u slučaju 5, gdje se u skupu za učenje nalaze samo podaci izmjereni pod opterećenjima od 0, 3 i 5 kg, dok se u

slučaju 6 u skupu za učenje ne nalaze podaci o signalima prikupljenima tijekom izvršavanja radnje bez opterećenja i pod maksimalnim opterećenjem od 5 kg.

**Tablica 8. Odstupanja od željenog izlaza neuronskih mreža za različite slučajeve**

Opterećenje	Maksimalno apsolutno odstupanje, [kg]					
	Slučaj 1	Slučaj 2	Slučaj 3	Slučaj 4	Slučaj 5	Slučaj 6
Bez opterećenja	0,0023	0,0016	0,0038	0,0028	0,0020	0,2295
1 kg	0,0123	0,0178	0,0212	0,0094	0,0528	0,0178
2 kg	0,0233	0,0085	0,0190	0,2722	0,2636	0,0097
3 kg	0,0083	0,0037	0,0025	0,0041	0,0033	0,0037
4 kg	0,0087	0,0045	0,2369	0,0724	0,4458	0,0004
5 kg	0,0083	0,0224	0,0004	0,0287	0,0033	0,9867

### 3.5. Mogućnost ponovljivog korištenja neuronske mreže


Nakon što je razrađen problem izrade sustava neuronske mreže korištenjem algoritma na samo jednom ispitaniku, postavlja se pitanje može li se istrenirana neuronska mreža koristiti na istom ispitaniku, ali prilikom drugog korištenja. Iz teorijske osnove elektromiografije poznato je da se karakteristike signala mijenjaju ovisno o mjestu postavljanja elektroda i tkivu između mišića i elektroda. Prilikom novog korištenja sustava nemoguće je postaviti elektrode na točno ona mjesta na kojima su bile prilikom treniranja mreže i prvog korištenja. Uz to, fiziološke karakteristike tijela su podložne stalnim promjenama. Stoga je logično zaključiti da će amplitude značajki prikupljenih u različitim mjerenjima odstupati jedne od drugih. No jesu li ta odstupanja velika poput odstupanja između ispitanika, ili je moguće iskoristiti istreniranu mrežu bez obzira na razlike?

Poput analize odnosa značajki među ispitanicima, napravljena je usporedba tri mjerenja na istom ispitaniku.


Kod prve značajke, amplitude srednje apsolutne vrijednosti signala ne preklapaju se kroz različita opterećenja, ali postoje razlike u rasponima od mjerenja do mjerenja. Amplitude značajki za mjerenja bez opterećenja u rasponu su od 0 do 0,01, za opterećenja od 1 kg između 0,08 i 0,12, 2 kg između 0,16 i 0,25, za 3 kg protežu se od 0,35 do 0,50, 4 kg od 0,63 do 0,68

te kod mjerenja opterećenja od 5 kg u rasponu su od 0,98 do 1. Slika 38. i slika 39. te tablica 9. prikazuju iznesene podatke. Prema dosadašnjim podacima i analizi, moguće je pretpostaviti da će neuronska mreža imati problema kod estimacije opterećenja od 3 kg, jer su razlike amplituda u tom području najveće, a manja odstupanja javit će se kod opterećenja od 1, 2 i 4 kg, dok bi sustav trebao raditi s minimalnim odstupanjima u područjima bez opterećenja i opterećenja od 5 kg.

Kod ostalim značajki, tj. nagiba srednje apsolutne vrijednosti, duljine valnog oblika te energije signala, također ne dolazi do preklapanja visina amplituda kroz različita opterećenja, no postoje razlike kroz mjerenja. Najširi raspon amplituda kod svih značajki nalazi se u području mjerenja opterećenja od 3 kg, dok su nešto manje razlike u amplitudama pri mjerenjima od 2 i 4 kg. Mjerenja maksimalnog i minimalnog opterećenja ponovno pokazuju vrlo bliske odnose amplituda značajki, te se prema tome ne očekuju problemi estimacije sile u tom području. Podaci su prikazani na tablicama 10., 11. i 12., a iznosi svih značajki u mjerenjima prikazani su na sljedećim slikama, nagib srednje apsolutne vrijednosti na slikama 40. i 41., duljina valnog oblika na slikama 42. i 43., te energija signala slikama 44. i 45.



**Slika 38.** Iznosi srednje apsolutne vrijednosti za različita opterećenja na jednom ispitaniku u više mjerenja




**Slika 39. Usporedba srednjih vrijednosti prve značajke višestruko mjerenih na jednom ispitaniku i srednjih vrijednosti tih mjerenja i mjerenja ostalih ispitanika**

**Tablica 9. Iznosi srednje apsolutne vrijednosti EMG signala jednog ispitanika u više mjerenja**


Opterećenje		Mjerenje 1	Mjerenje 2	Mjerenje 3
Bez opterećenja	min.	0,0000	0,0000	0,0000
	sred. vr.	0,0002	0,0007	0,0008
	max.	0,0004	0,0010	0,0013
1 kg	min.	0,0850	0,1131	0,0844
	sred. vr.	0,0859	0,1139	0,0849
	max.	0,0863	0,1147	0,0853
2 kg	min.	0,1602	0,2521	0,1833
	sred. vr.	0,1619	0,2533	0,1849
	max.	0,1628	0,2541	0,1861
3 kg	min.	0,3548	0,4614	0,4990
	sred. vr.	0,3566	0,4644	0,5016
	max.	0,3572	0,4670	0,5036
4 kg	min.	0,6301	0,6756	0,6372
	sred. vr.	0,6354	0,6804	0,6424

	max.	0,6392	0,6846	0,6457
5 kg	min.	0,9971	0,9938	0,9848
	sred. vr.	0,9989	0,9973	0,9938
	max.	1,0000	1,0000	1,0000



**Slika 40.** Iznosi nagiba srednje apsolutne vrijednosti za različita opterećenja na jednom ispitaniku u više mjerenja






**Slika 41. Usporedba srednjih vrijednosti druge značajke višestruko mjerenih na jednom ispitaniku i srednjih vrijednosti tih mjerenja i mjerenja ostalih ispitanika**


**Tablica 10. Iznosi nagiba srednje apsolutne vrijednosti EMG signala jednog ispitanika u više mjerenja**

Opterećenje		Mjerenje 1	Mjerenje 2	Mjerenje 3
Bez opterećenja	min.	0,0000	0,0000	0,0000
	sred. vr.	0,0011	0,0012	0,0061
	max.	0,0018	0,0017	0,0091
1 kg	min.	0,0807	0,0984	0,0636
	sred. vr.	0,0842	0,0989	0,0673
	max.	0,0951	0,0998	0,0737
2 kg	min.	0,1508	0,2170	0,1421
	sred. vr.	0,1574	0,2259	0,1505
	max.	0,1674	0,2379	0,1626
3 kg	min.	0,3439	0,4069	0,4055
	sred. vr.	0,3480	0,4192	0,4554
	max.	0,3535	0,4249	0,4835
4 kg	min.	0,6844	0,5856	0,5550

	sred. vr.	0,7150	0,6479	0,6067
	max.	0,7271	0,6695	0,6298
5 kg	min.	0,8642	0,8269	0,8881
	sred. vr.	0,9049	0,9155	0,9635
	max.	1,0000	1,0000	1,0000



**Slika 42. Iznosi duljina valnog oblika signala za različita opterećenja na jednom ispitaniku u više mjerenja**




**Slika 43. Usporedba srednjih vrijednosti treće značajke višestruko mjerenih na jednom ispitaniku i srednjih vrijednosti tih mjerenja i mjerenja ostalih ispitanika**


**Tablica 11. Iznosi duljina valnog oblika EMG signala jednog ispitanika u više mjerenja**

Opterećenje		Mjerenje 1	Mjerenje 2	Mjerenje 3
Bez opterećenja	min.	0,0000	0,0000	0,0000
	sred. vr.	0,0000	0,0001	0,0001
	max.	0,0000	0,0002	0,0002
1 kg	min.	0,0132	0,0193	0,0209
	sred. vr.	0,0134	0,0195	0,0212
	max.	0,0135	0,0198	0,0215
2 kg	min.	0,0352	0,0730	0,0650
	sred. vr.	0,0358	0,0739	0,0657
	max.	0,0362	0,0746	0,0663
3 kg	min.	0,1449	0,2168	0,3063
	sred. vr.	0,1457	0,2211	0,3073
	max.	0,1461	0,2251	0,3098
4 kg	min.	0,4097	0,4739	0,4418

	sred. vr.	0,4204	0,4820	0,4534
	max.	0,4298	0,4891	0,4622
5 kg	min.	0,9899	0,9685	0,9488
	sred. vr.	0,9952	0,9842	0,9772
	max.	1,0000	1,0000	1,0000



**Slika 44.** Iznosi energije signala za različita opterećenja na jednom ispitaniku u više mjerenja




Slika 45. Usporedba srednjih vrijednosti četvrte značajke višestruko mjerenih na jednom ispitaniku i srednjih vrijednosti tih mjerenja i mjerenja ostalih ispitanika

Tablica 12. Iznosi energije EMG signala jednog ispitanika u više mjerenja

Opterećenje		Mjerenje 1	Mjerenje 2	Mjerenje 3
Bez opterećenja	min.	0,0000	0,0000	0,0000
	sred. vr.	0,0004	0,0011	0,0036
	max.	0,0010	0,0030	0,0071
1 kg	min.	0,0572	0,0837	0,0342
	sred. vr.	0,0617	0,0868	0,0422
	max.	0,0658	0,0899	0,0495
2 kg	min.	0,1134	0,1866	0,1489
	sred. vr.	0,1191	0,1951	0,1569
	max.	0,1241	0,2051	0,1636
3 kg	min.	0,3110	0,3818	0,4952
	sred. vr.	0,3157	0,3860	0,5058
	max.	0,3198	0,3888	0,5148
4 kg	min.	0,6008	0,6489	0,5726

	sred. vr.	0,6177	0,6755	0,5985
	max.	0,6406	0,6976	0,6251
5 kg	min.	0,9558	0,8933	0,9138
	sred. vr.	0,9808	0,9491	0,9605
	max.	1,0000	1,0000	1,0000


Podacima mjerenja 3 testiran je rad neuronske mreže, koja je trenirana djelomičnim podacima svih opterećenja mjerenja 1, te je dobiveni izlaz mreže prikazan na slici 46. Odstupanje dobivenog izlaza od željenog je minimalno kod opterećenja u kojima su male razlike u amplitudama značajki, tj. za mjerenja bez opterećenja, opterećenje od 4 kg i 5 kg. Odstupanje je nešto veće za odziv na opterećenje od 1 i 2 kg, u maksimalnom iznosu od 0,09 kg odnosno 0,08 kg. Najveće odstupanje je kod odziva mreže na podatke mjerenja opterećenja od 3 kg, u maksimalnom iznosu od 0,48 kg. Odstupanje od skoro 50% nije prihvatljivo. Stoga su među podatke za učenje mreže uvršteni uzorci mjerenja 3 za podizanje tereta od 3 kg., te je odziv prikazan na slici 47.



**Slika 46. Odziv neuronske mreže na nepoznate podatke mjerenja 3**


Odziv mreže nakon što je u podatke za učenje uvršten dio podataka iz mjerenja 3 manje odstupa u djelomično poznatom području opterećenja od 3 kg (odstupanje 0,05 kg), ali javljaju se nešto veća odstupanja u područjima opterećenja gdje ih nije bilo. Tako se kod procjene opterećenja

1, 2 i 4 kg javlja odstupanje od 0,18 do 0,26 kg, te kod procjene maksimalnog opterećenja od 5 kg odstupanje od 0,08 kg.




**Slika 47 . Odziv neuronske mreže na djelomično nepoznate podatke mjerenja 3, poznati podaci za opterećenje 3 kg**

Pošto je za normalizaciju značajki potrebno napraviti barem jedno mjerenje za opterećenje od 5 kg, to mjerenje može se iskoristiti kako bi pomoglo u smanjenju greške neuronske mreže. Najbolji odziv mreže za mjerenje 3 dobiven je kada je u podatke za učenje nadodan dio uzoraka dobivenih mjerenjem opterećenja mišića teretom 3, 4 i 5 kg, dakle nisu uvršteni podaci mjerenja bez opterećenja te pod opterećenjima od 1 i 2 kg. Odstupanja od željenog izlaza mreže u ovom su slučaju pala ispod 0,18 kg (najgori slučaj) te čak u velikom broju uzoraka ispod 0,08 kg. Odzivi su prikazani slikom 48.



**Slika 48. Odziv neuronske mreže na djelomično nepoznate podatke mjerenja 3, djelomično poznati podaci za opterećenje 3, 4 i 5 kg**


Poput testiranja neuronske mreže s podacima mjerenja 3, provedeno je ispitivanje mreže s podacima mjerenja 2. Ponovno su vidljiva odstupanja koja se podudaraju s razlikama amplituda značajki za pojedina opterećenja, slika 49.



**Slika 49. Odziv neuronske mreže na nepoznate podatke mjerenja 2**




Ovoga puta dodavanje dijela podataka iz mreži nepoznatog mjerenja 2 nije smanjilo odstupanja željenog odziva mreže od dobivenog. Za neka opterećenja odstupanja iznose čak 0.74 kg. Na slici 50. prikazan je odziv mreže kojoj su u podatke za učenje dodani uzorci iz mjerenja 2 prikupljeni mjerenjem signala pri teretu od 3 kg.



**Slika 50. Odziv neuronske mreže na djelomično nepoznate podatke mjerenja 2, djelomično poznati podaci za opterećenje 3 kg**

Na slici 49. moguće je primijetiti da dobiven izlaz s podacima mjerenja 2 slični izlazu dobivenom iz naučenih podataka, s uvećanjem za određeni koeficijent. Slika 51. prikazuje odziv neuronske mreže kada se podaci za učenje mjerenja 1 uvećaju za 30%. Najveće odstupanje iznosi 0,32 kg pri estimaciji opterećenja od 2 kg, dok su ostale procjene unutar manjih odstupanja.



**Slika 51. Odziv neuronske mreže na nepoznate podatke mjerenja 2 s uvećanim podacima za učenje**

Maksimalna apsolutna odstupanja dobivenih izlaza iz mreže u odnosu na željene nalazi se u tablici 13. U slučaju 1 testirani su podaci mjerenja 3 na mreži naučenoj na podacima mjerenja 2. U slučaju 2 u skup za treniranje mreže dodani su djelomično uzorci mjerenja 3 dobiveni prilikom mjerenja pod opterećenjem od 3 kg, a u slučaju 3 dodani su djelomični uzorci mjerenja 3 za opterećenja od 3, 4 i 5 kg. Slučaj 4 prikazuje odstupanja mreže trenirane podacima mjerenja 1, a testirane podacima mjerenja 2, dok se u slučaju 5 u podatke za učenje dodao dio uzoraka iz mjerenja 2, za opterećenje od 3 kg. U slučaju 6 mreža podaci za treniranje mjerenja 1 uvećani su za određen koeficijent, te je zatim mreža testirana na podacima mjerenja 2.

**Tablica 13. Odstupanja od željenog izlaza neuronskih mreža za različite slučajeve na više mjerenja**

Opterećenje	Maksimalno apsolutno odstupanje, [kg]					
	Slučaj 1	Slučaj 2	Slučaj 3	Slučaj 4	Slučaj 5	Slučaj 6
Bez opterećenja	0,0084	0,0098	0,0104	0,0050	0,0104	0,0038
1 kg	0,0874	0,1807	0,0752	0,4162	0,3502	0,0161
2 kg	0,0857	0,2115	0,1841	0,5901	0,7361	0,3209
3 kg	0,4815	0,0458	0,0475	0,4353	0,0181	0,1433

4 kg	0,0324	0,2603	0,0782	0,1574	0,7280	0,0889
5 kg	0,0370	0,0814	0,0304	0,0229	0,0001	0,0187

Uzevši u obzir analizu značajki elektromiografskog signala te način rada mreže prilikom jednog mjerenja i više mjerenja, doneseno je nekoliko prijedloga za zadovoljavajući rad sustava.

Za najpreciznije rezultate, korisnik sustava trebao bi prilikom svakog korištenja izvršiti umjeravanje snimanjem signala tijekom vršenja zadane radnje bez opterećenja te pod različitim opterećenjima. Kao što je prikazano ranije, nije nužno izvršiti mjerenja sa svim opterećenjima, premda se time dobiva na preciznosti, ali je važno uvrstiti granična opterećenja.

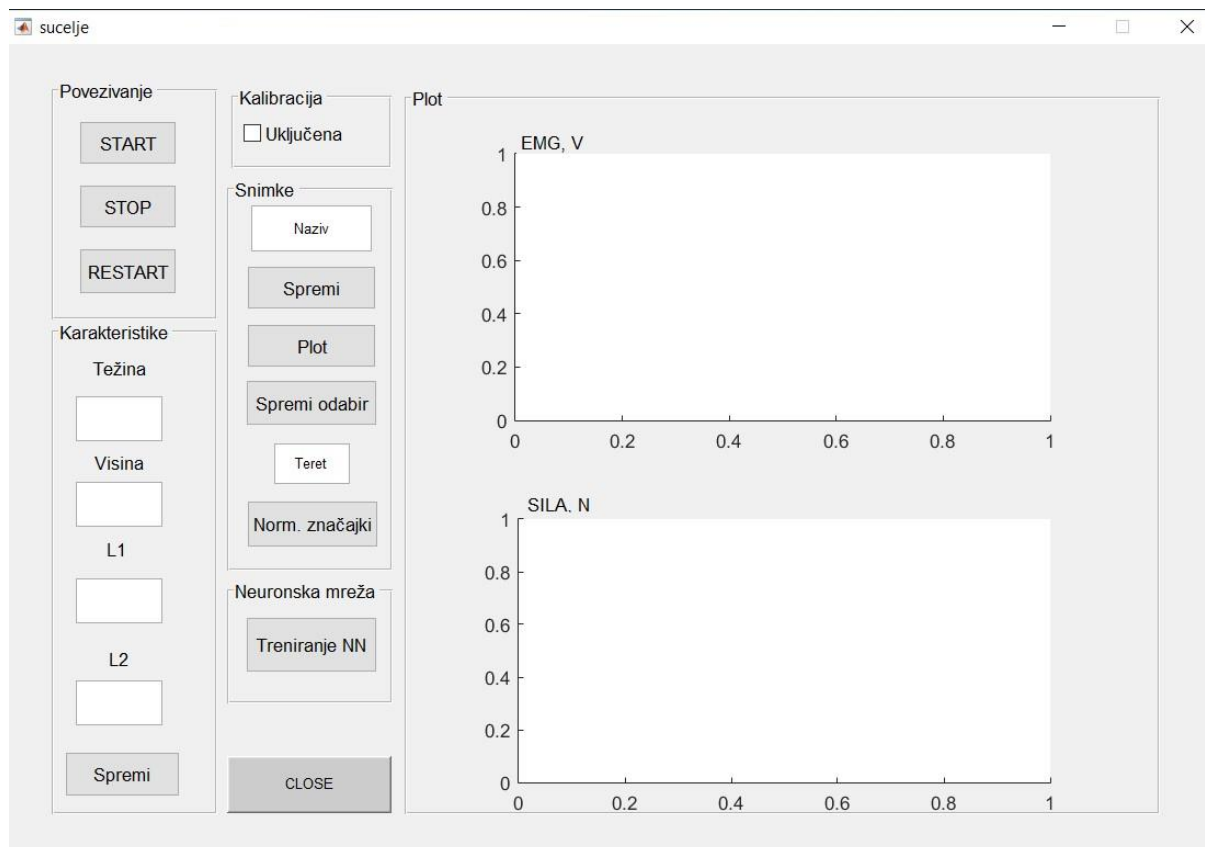
Kod ponovnog korištenja sustava predlaže se da korisnik isproba sustav s poznatim opterećenjima bez dodatnih treniranja mreže. Ako je uočeno jedno ili dva odstupanja, predlaže se dodavanje uzoraka izmjerenih pri opterećenjima na kojima je uočeno odstupanje te ponovno treniranje mreže. Ako je uočen trend, tj. svi odzivi su za određen koeficijent veći ili manji od željenog odziva, predlaže se množenje podataka za učenje mreže koeficijentom koji je procijenjen, te ponovno treniranje mreže s tim podacima. Time bi se smanjila potreba ponavljanja svih mjerenja prije svakog korištenja sustava.

Bez obzira na dodatna umjeravanja koja je potrebno učiniti prilikom korištenja sustava, neuronska mreža trenirana podacima samo jednog ispitanika daje smislenija rješenja naspram mreže trenirane na podacima svih ispitanika, tj. odstupanja ne prelaze 100%.

### 3.6. Program za procjenu sile dvoglavog nadlaktičnog mišića u stvarnom vremenu


U MATLAB-u je napravljeno korisničko sučelje za prikaz elektromiografskog signala i opterećenja, te olakšanu kalibraciju, prikupljanje podataka i korištenje neuronske mreže. Sučelje je prikazano na slici 52., a sastavni dijelovi su:

- Povezivanje MATLAB-a s mikrokontrolerom
- Unos karakteristika ispitanika
- Kalibracija sustava
- Prikupljanje podataka elektromiografskog signala i željenih značajki
- Pristup učenju neuronske mreže
- Prikaz podataka dobivenih sa senzora i izlaza iz neuronske mreže.



**Slika 52. Korisničko sučelje**

Pritiskom na tipku *START*, uspostavlja se veza između Arduina i MATLAB-a. Arduino prikuplja signale frekvencijom od 1000 Hz u skupovima po 200 uzoraka te ih šalje MATLAB-u. Uzorci prolaze kroz filtraciju i ispravljanje. Prilikom prvog korištenja sustava, potrebno je izraditi bazu podataka u kojoj se nalaze signali prikupljeni pod različitim opterećenjima, koji će služiti za izradu neuronske mreže za estimaciju sile mišića. Stoga je prilikom prvog korištenja potrebno označiti polje *Uključena* u području *Kalibracija*. Time se programu daje do znanja da je baza podataka prazna i ne vrše se izračuni sila koji bi mogli uzrokovati greške u radu. Prilikom umjeravanja sustava korisnik vrši zadane radnje pod zadanim opterećenjima te unosom teksta u polje *Naziv* i pritiskom na tipku *Spremi* u području *Snimke* izmjereni signali se spremaju. Zatim iz spremljenog signala potrebno odabrati dijelove signala u kojima se izvršavao zadani pokret ili položaj. Pritiskom na tipku *Plot* otvara se novi dio sučelja u kojemu je moguće izabrati dijelove grafa koji su bitni za sustav. Pošto je do sada za umjeravanje sustava korišteno tri ponavljanja radnje za svako opterećenje, namješteno je da korisnik označi 6 točaka na dijagramu, tj. početak i kraj korisnog dijela signala, slika 53.




**Slika 53. Odabir početka i kraja signala opterećenja**

Nakon odabira točaka, dodatni prozor je potrebno zatvoriti. U tekstualno polje *Teret* upisuje se opterećenje na koje se odnosi snimka. Ta informacija je potrebna za treniranje neuronske mreže, željeni izlaz. Ako je u pitanju podizanje tereta od 5 kg, maksimalnog opterećenja, dodatno se pritisne tipka *Norm. Značajki*. Razlog tomu je normalizacija signala prije ulaska u neuronsku mrežu, te prema tim vrijednostima bit će normalizirani signali za vrijeme rada sustava.

Pritiskom na tipku *Treniranje NN* podaci se šalju neuronskoj mreži, te se izvršava učenje. Mreža se sprema i šalje u funkciju koja simulira njen rad u stvarnom vremenu, *simulateNet.m*.

Izlaz iz mreže se ovisno o karakteristikama koje je korisnik unio u polja *Težina*, *Visina*, *L1* (duljini podlaktice) i *L2* (duljini podlaktice i centra šake) skalira prema modelu na jednadžbi 18.

Nakon postavljanja sustava isključuje se polje *Uključena* kalibracija. Podaci koji se šalju s mikrokontrolera u skupovima ulaze u funkciju *sakupiZnacajke.m* gdje se pretvaraju u željene značajke signala. Potom se prema ranije spremljenoj maksimalnoj vrijednosti normaliziraju. Takve ulaze u funkciju *simulateNet.m* koja omogućava rad neuronske mreže u realnom vremenu. Izlaz iz mreže se potom skalira kako je ranije objašnjeno i prikazuje na drugom grafu u sučelju, slika 54.




**Slika 54. Estimacija sile na ispitaniku 1 prilikom podizanja tereta od 5 kg**

Iz mjerenja signala u realnom vremenu vidljivo je da neuronska mreža estimira silu koja je potrebna za podizanje tereta, u ovom slučaju kod ispitanika 1 to znači 405 N za opterećenje od 5 kg. Rad mreže u realnom vremenu nestabilniji je od rada off-line. Postoji veća varijacija u podacima naspram rada samo određenim podacima snimljenim u optimalnim uvjetima. Za budući rad bilo bi korisno razviti dodatan algoritam stabilizacije rada mreže, uzimajući u obzir podatke o silama u vremenu prije trenutnog te promjenama položaja ruke.

### 3.7. Rad sustava s ostalim mišićima


Kako bi zamišljeni sustav mogao imati svoju primjenu u interakciji čovjeka s računalom i/ili robotom, sustav estimacije sile pomoću elektromiografskog signala potrebno je proširiti na ostale mišiće ruke. Pokreti ruke zavisni su o mišićima podlaktice i nadlaktice, te ih je potrebno gledati kao cjelinu. Tvorba modela za svaki mišić od interesa dovodi do procjene sila koje se razvijaju u njima. Korištenjem kinematskog modela ruke, prema naučenim podacima u zadanim položajima, cilj je doći do sila kojima ruka djeluje na okolinu, i prema tome razraditi modele kojima bi robotski sustav djelovao poput čovjeka.

Trenutno je razjašnjena problematika samo izometričke kontrakcije dvoglavog nadlaktičnog mišića. Sljedeći korak je promatranje izometričke kontrakcije troglavog nadlaktičnog mišića, slika 55.



**Slika 55. Troglavi nadlaktični mišića [19]**

Mjerenja su izvršena samo na jednom ispitaniku, pošto veći broj ispitanika ne doprinosi boljem radu sustava. Ispitanik tijekom mjerenja zauzima položaj prikazan na slici 56., dakle u trupu je sagnut za  $45^\circ$  te podiže teret u ravninu trupa. Time je dobivena maksimalna kontrakcija tricepsa, uz malu ili nikakvu aktivnost ostalih mišića, čime je omogućena procjena sile razvijene u mišiću.



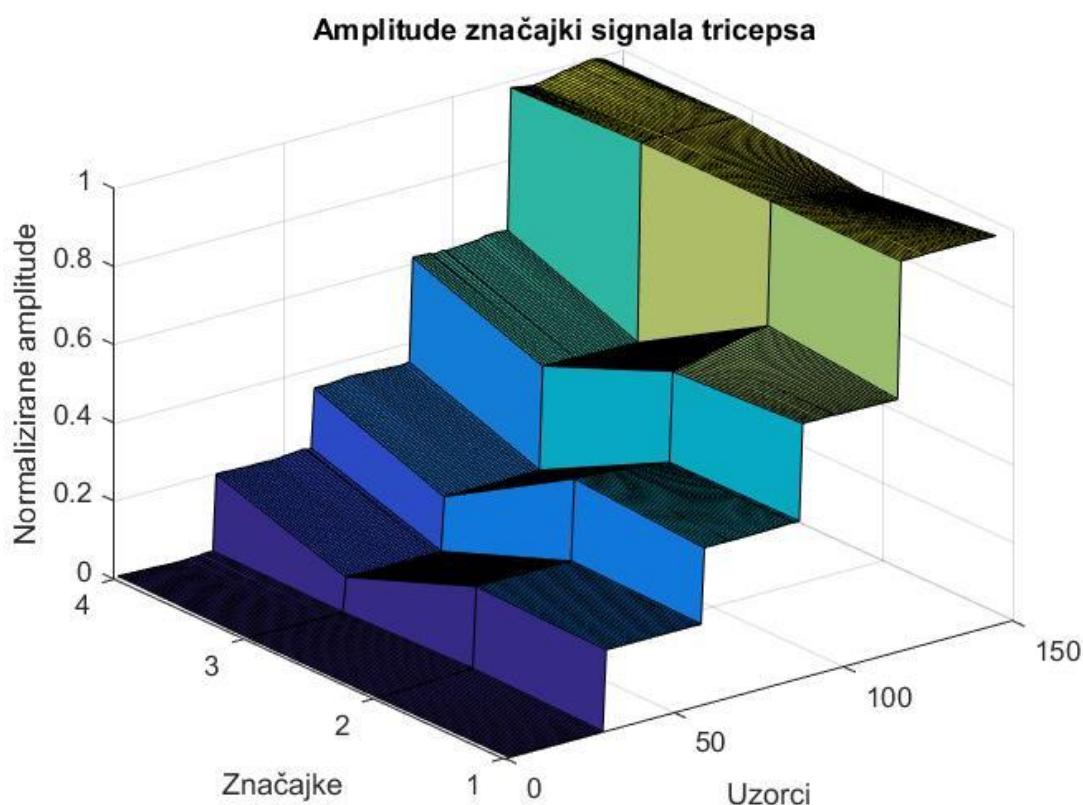
**Slika 56. Položaj ruke i tijela tijekom prikupljanja značajki za troglavi nadlaktični mišić [20]**

Prema slici 56. postavljen je jednostavan model izračuna sile koju triceps mora proizvesti za pridržavanje tereta. Model je važeći za stacionarno držanje tereta odnosno izometričku kontrakciju. Model je objašnjen jednadžbom (18)

gdje  $\alpha$  predstavlja nagib tijela i ruke,  $F_t$  silu tereta i  $F_{tric}$  silu razvijenu u mišiću.

$$F_{tric} = \frac{F_t}{\cos(\alpha)}, \quad (18)$$


Mjerenja su izvršena kao i za biceps, ponavljanjem radnje tri puta s pauzama između i pridržavanjem položaja kroz 6 sekundi. Potom je signal obrađen te su izračunate četiri ranije korištene značajke. Ponovno je vidljiva razlučivost između amplituda signala različitih opterećenja, slika 57.



**Slika 57. Prikupljene značajke za signal tricepsa**

Prikupljene značajke korištene su kao ulazni vektor procjene sile tricepsa. Neuronska mreža za estimaciju sile kao i kod bicepsa ima 2 neurona skrivenog sloja. Odziv mreže trenirane na djelomičnim podacima mjerenja prikazan je na slici 58.






**Slika 58. Odziv neuronske mreže tricepsa**


Cilj je kombinacijom izlaza iz mreže i jednadžbom jednostavnog modela može dobiti iznos sile koja je tricepsu potrebna za izvršavanje zadanih radnji. U ovom slučaju javlja se problem preciznosti zamišljenog sustava. Ponovljivost izvršavanja radnji pod točnim kutom nije izvediva bez dodatne opreme. Nije moguće uspostaviti normalizaciju podataka. Za kvalitetan rad sustava potrebno je uvesti dodatni oblik kontrole izvršavanja radnji. Jedan od prijedloga za buduća istraživanja je korištenje vizijskog sustava s markerima postavljenima na tijelo ispitanika. Signal bi se tada mjerio samo u trenutku kada ispitanik zauzme točan položaj, čime bi se odstranio čimbenik ljudske pogreške.

Također, sustav je potrebno primijeniti i na mišiće podlaktice. Elektrode su postavljene na ularni pregibač zapešća (lat. *musculus flexor carpi ulnaris*) i mišiće pregibače prstiju ((lat. *musculus flexor digitorum*), pošto površinskom elektrodom nije moguće doći do izoliranog mišića, te na ularni ispružać zapešća (lat. *musculus extensor carpi ulnaris*) i mišiće ispružaće prstiju (lat. *musculus extensor digitorum*), slika 59.




**Slika 59. Mišići podlaktice [21]**

Ponovno je vidljiva distinkcija značajki signala kroz različita opterećenja (0 - 3 kg), slika 60. i slika 61.




**Slika 60. Značajke pri različitim opterećenjima, ulnarni pregibač zapešća**



**Slika 61. Značajke pri različitim opterećenjima, ulnarni ispružać zapešća**

Problem koji se javlja kod izrade modela sustava za mišiće podlaktice je poteškoća pronalaska položaja u kojemu bi se mjerenja mogla izvršiti za različita opterećenja uz dobru ponovljivost. Nekoliko je konfiguracija položaja tijela testirano, ali niti jedna se nije pokazala iskoristivom. Za razliku od bicepsa i tricepsa, i mali rotacijski pomaci zapešća izazivaju značajne amplitude, a sile koje se razvijaju nije moguće odrediti samo mehaničkim modelom. Vrlo je teško pod opterećenjem pridržavati traženi položaj, koji je za željena mjerenja na ovim mišićima otežano i zauzeti, jer su mišići podlaktice slabiji od mišića nadlaktice, a iz manjih razlika opterećenja ne dobivaju se dovoljne raznolikosti u amplitudama značajki. Za precizna mjerenja sila razvijenih u podlaktici potrebno je koristiti dodatne senzore sila, kada je u pitanju sila koju stvara rotacija zapešća, ili senzore tlaka, ako je od interesa sila stiska šake, slika 62.



**Slika 62. Dodatni senzori za procjenu sila mišića podlaktice [22], [23]**

Korištenjem samo elektromiografskog senzora, bez dodatnih senzora sila i kamera nije moguće izraditi cijeli sustav za estimaciju sila mišića u ruci i izvršiti njegovu primjenu u interakciji s robotskim sustavima.

## 4. ZAKLJUČAK

U ovom radu razrađena je ideja korištenja neuronske mreže na podacima elektromiografskog signala za procjenu sila koje se razvijaju u mišićima tijekom izvršavanja radnji. Dosadašnja istraživanja daju podijeljenu sliku o mogućnosti korištenja veze između sile i amplitude elektromiografskog signala. U razvoju sustava su stoga korištena mjerenja izometrične kontrakcije mišića, kod koje je moguće napraviti poveznicu između sile i signala. Zbog nelinearnosti u odnosu elektromiografskog signala i sile u mišićima amplitudne značajke nije moguće jednostavno preslikati na opterećenja kod kojih se javljaju, već je kao metoda za estimaciju izabrana je umjetna neuronska mreža. Neuronska mreža može izvući bitne značajke iz kompleksnih uzoraka te ih generalizirati na uzorke s kojima se još nije susrela.

Prvi zahtjev kod rada sustava mogućnost je korištenja istog na više korisnika. Napravljena je neuronska mreža prema podacima pet ispitanika. Željeni izlaz iz mreže odstupao je od traženog. Za uvid u razlog odstupanja napravljena je analiza značajki signala kojima je trenirana i testirana neuronska mreža. Ispostavilo se da je razlog odstupanja višeznačnost podataka koje ulaze u mrežu. Mjere jednog ispitanika prikupljene za vrijeme nižeg opterećenja imale su slične amplitudne vrijednosti podacima drugog ispitanika prikupljenim mjerenjem tijekom višeg opterećenja.

Napravljena je analiza podataka jednog ispitanika i testirana neuronska mreža s podacima samo jednog ispitanika. Dobivena su manja odstupanja naspram neuronskoj mreži treniranoj na podacima svih ispitanika. Donesen je prijedlog za korištenje sustava na samo jednom korisniku, tj. neuronska mreža kod svakog novog korisnika mora proći kroz trening uzimajući podatke samo tog korisnika. Potvrđena je prednost korištenja neuronske mreže kao metode estimacije sile jer kod testiranja na nepoznatim uzorcima čiji odnos sa silom nije linearan, tj. postoje rasipanja u amplitudama te nelinearni skokovi pri nekim opterećenjima, dobiveni izlazi iz mreže su i dalje zadovoljavajući.

Razmatran je problem ponovnog korištenja treniranog sustava. Prilikom novog korištenja postoje razlike u amplitudama značajki, a razlog tome je činjenica da elektrode nije moguće postaviti na identična mjesta na kojima su bile prilikom treniranja sustava i konstantne promjene u fiziologiji čovjeka. Stoga je nakon analize značajki i testiranja mreže na više mjerenja doneseno nekoliko prijedloga za ponovno korištenje sustava. Korisnik treba prema poznatim opterećenjima procijeniti daje li sustav zadovoljavajuća rješenja. Ako veći dio

mjerenja daje dobar odziv uz odstupanje prilikom određenog opterećenja, podatke mjerenja tog opterećenja potrebno je uvrstiti u skup za učenje mreže. Ako je uočen trend, tj. dobiveni izlaz odstupa za određeni koeficijent od željenog izlaza kod svih poznatih opterećenja, skup za učenje može se pomnožiti koeficijentom kako bi se dobila manja odstupanja. Za najprecizniji rad sustava predlaže se ponovno umjeravanje sustava prilikom svakog korištenja, no dotreniranjem postojeće neuronske mreže moguće je dobiti zadovoljavajuće rezultate, što ponovo ukazuje na jednu od prednosti neuronskih mreža, mogućnost generalizacije.

Za lakšu vizualizaciju signala, obradu podataka te korištenje neuronske mreže napravljeno je korisničko sučelje koje radi u realnom vremenu. Na sučelju postoji prikaz signala dobivenog iz mikrokontrolera te estimacije sile dobivene iz neuronske mreže. Estimacija sile u realnom vremenu nestabilnija je od rada off-line. Za budući rad bilo bi korisno osmisliti algoritam stabilizacije izlaza neuronske mreže.

Za primjenu estimirane sile na robotski sustav potrebno je uzeti u obzir aktivacije ostalih mišića nadlaktice i podlaktice. Zbog nemogućnosti dobivanja modela kojima bi se aproksimirala sila razvijena u mišićima bez dodatne opreme poput senzora sile i vizijskog sustava javio se problem izrade cjelokupnog sustava. Podaci samo jednog mišića ne dozvoljavaju korištenje sustava u interakciji s robotom, nepoznate su ostale sile kojima bi se odredilo djelovanje čovjeka koje bi robot oponašao.

Sugestija za budući rad je korištenje dodatnih senzora i vizijskog sustava za dobivanje cjelokupnog modela te proučavanje veze između sila i izotoničkih kontrakcija kako bi sustav dobio uvid u dinamičke pokrete.

## LITERATURA

- [1] Basmajian, J. V., De Luca, C. J., Muscle Alive: Their Function Revealed by Electromyography, Baltimore, Williams & Wilkins, pp.201-222, 1985.
- [2] Konard, P., The ABC of EMG: A Practical Introduction to Kinesiological Electromyography, Noraxon Inc. USA, version 1.0 April 2005.
- [3] Reaz, M.B.I., Hussain, M.S., Mohd-Yasin, F., Techniques of EMG signal analysis: detection, processing, classification and applications, Biol. Proced. Online (2006) 8: 11. <https://doi.org/10.1251/bpo115>
- [4] Muscle structure, <https://www.carlsonstockart.com/photo/muscle-structure-illustration>, 1.6.2019.
- [5] An Unofficial Introductory Tutorial to MyoWare Muscle Sensor Development Kit, <https://medium.com/@leex5202/an-unofficial-introductory-tutorial-to-myoware-muscle-sensor-development-kit-e2169948e63>, 1.7.2019.
- [6] EMG Analysis and EMG Graphing User Guide, Motion Lab Systems. February 24, 2009
- [7] Liu, M.M., Herzog, W., Savelberg, H., Dynamic muscle force predictions from EMG: An artificial neural network approach. Journal of Electromyography and Kinesiology 9(6):391-400, 1999.
- [8] Jovanović, K., Vranić, J., Miljković, N., Hill's and Huxley's muscle models - tools for simulations in biomechanics. Serbian Journal Of Electrical Engineering, Vol. 12, No. 1, February 2015, 53-67
- [9] Sivanandam, S. N., Deepa, S. N., Introduction to Neural Networks Using Matlab 6.0. Tata McGraw-Hill Education, New Delhi, 2006.
- [10] Hecht-Nielsen, R., Theory of the Backpropagation Neural Network. Neural Networks. 1. 593 - 605 vol.1. 10.1109/IJCNN.1989.118638., 1989.
- [11] McCulloch-Pitts Neuron, <https://towardsdatascience.com/mcculloch-pitts-model-5fdf65ac5dd1>, 1.6.2019.
- [12] Dalbelo Bašić, B., Čupić, M., Šnajder, J., Umjetne neuronske mreže, Fakultet elektrotehnike i računarstva, Zagreb, 2008.
- [13] Novaković, B., Majetić, D., Široki, M., Umjetne neuronske mreže, Fakultet strojarstva i brodogradnje, Zagreb, 1998.
- [14] Feedforward Neural Network, <http://web.utk.edu/~wfeng1/spark/fnn.html>, 1.7.2019.

- [15] Backyardbrains Muscle SpikerShield Pro, <https://backyardbrains.com/products/MuscleSpikerShieldPro>, 1.6.2019.
- [16] Hislop, H., Montgomery, J., Daniels and Worthingham's Muscle Testing: Techniques of Manual Examination. St. Louis, Mo. :Saunders Elsevier, 2007.
- [17] Biceps force, <http://session.masteringphysics.com/problemAsset/1013607/12/jfk.Figure.P08.37.jpg>, 15.6.2019.
- [18] Plagenhoef, S., Anatomical Data for Analyzing Human Motion. Research Quarterly for Exercise and Sport, Vol. 54, No.2, PP. 169-178, 1983.
- [19] Triceps Brachii Muscle, <https://www.yoganatomy.com/triceps-brachii-muscle>, 15.6.2019.
- [20] Bent Over Double Arm Tricep Kickbacks, <https://workoutlabs.com/exercise-guide/bent-over-double-arm-tricep-kickbacks>, 15.6.2019.
- [21] Forearm pain, <https://www.nomorepainergonomics.com.au/blogs/no-more-pain-ergonomics/117453509-forearm-pain>, 1.7.2019.
- [22] Dahlvist C., Nordander C., Granqvist L., Forsman M., Hansson GÅ., Comparing two methods to record maximal voluntary contractions and different electrode positions in recordings of forearm extensor muscle activity: Refining risk assessments for work-related wrist disorders. Work. 2018;59(2):231-242.
- [23] Park, J. B., Xu, D., Multi-Finger Interaction and Synergies in Finger Flexion and Extension Force Production, Frontiers in Human Neuroscience, Vol. 11, 2017.



## **PRILOZI**

I. CD-R disc