

Regresijsko modeliranje pneumatskog mišića korištenjem algoritama umjetne inteligencije

Ključević, Mario

Master's thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Engineering / Sveučilište u Rijeci, Tehnički fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:190:041062>

Rights / Prava: [Attribution 4.0 International](#)/[Imenovanje 4.0 međunarodna](#)

Download date / Datum preuzimanja: **2025-01-04**



Repository / Repozitorij:

[Repository of the University of Rijeka, Faculty of Engineering](#)



SVEUČILIŠTE U RIJECI

TEHNIČKI FAKULTET

Diplomski sveučilišni studij elektrotehnike

Diplomski rad

**REGRESIJSKO MODELIRANJE PNEUMATSKOG MIŠIĆA
KORIŠTENJEM ALGORITAMA UMJETNE INTELIGENCIJE**

Rijeka, rujan 2024.

Mario Ključević

0069084600

SVEUČILIŠTE U RIJECI
TEHNIČKI FAKULTET

Diplomski sveučilišni studij elektrotehnike

Diplomski rad

**REGRESIJSKO MODELIRANJE PNEUMATSKOG MIŠIĆA
KORIŠTENJEM ALGORITAMA UMJETNE INTELIGENCIJE**

Mentor : prof. dr. sc. Zlatan Car

Komentor: Sandi Baressi Šegota, mag. ing. comp.

Rijeka, rujan 2024.

Mario Ključević

0069084600

Rijeka, 14.03.2024.

Zavod: Zavod za automatiku i elektroniku
Predmet: Osnove robotike

ZADATAK ZA DIPLOMSKI RAD

Pristupnik: **Mario Ključević (0069084600)**
Studij: Sveučilišni diplomski studij elektrotehnike (1300)
Modul: Automatika (1331)

Zadatak: **Regresijsko modeliranje pneumatskog mišića korištenjem algoritama umjetne inteligencije / Regression modeling of pneumatic muscle using artificial intelligence models**

Opis zadatka:

Izvršiti pregled literature iz područja primjene pneumatskih mišića i regresijskog modeliranja. Kreirati set podataka temeljen na podacima proizvođača za različite vrste pneumatskih mišića. Kombinirati setove podataka u zajednički. Izvršiti statističku analizu prikupljenih setova podataka. Korištenjem regresijskog algoritma umjetne inteligencije kreirati modele za predviđanje ponašanja pojedinačnih pneumatskih mišića, te generalni model. Usporediti performanse modela. Diplomski rad mora biti napisan prema uputama za pisanje diplomskih radova koje su objavljene na mrežnim stranicama studija.

Rad mora biti napisan prema Uputama za pisanja diplomskih / završnih radova koje su objavljene na mrežnim stranicama studija.

Zadatak uručen pristupniku: 20.03.2024.

Mentor:
prof. dr. sc. Zlatan Car

Komentor:
Sandi Baressi Šegota

Predsjednik povjerenstva za
diplomski ispit:
prof. dr. sc. Dubravko Franković

IZJAVA

Sukladno članku 9. Pravilnika o diplomskom radu, diplomskom ispitu i završetku diplomskih sveučilišnih studija Tehničkog fakulteta Sveučilišta u Rijeci izjavljujem da sam izradio ovaj diplomski rad samostalno, koristeći vlastito znanje i navedenu literaturu, u razdoblju od datuma zadavanja zadatka do datuma predaje.

Rijeka, rujan 2024.

Mario Ključević

A handwritten signature in black ink, appearing to read 'Mario Ključević', is written over a horizontal line.

ZAHVALA

Zahvaljujem svojoj obitelji na strpljenju, razumijevanju i podršci. Zahvala kolegama i prijateljima na lijepim uspomenama tijekom studiranja.

Zahvaljujem prof. dr. sc. Zlatanu Caru na prihvaćanju mentorstva za izradu rada i asist. Sandiju Baressi Šegoti, mag. ing. comp. na uputama i pomoći tijekom izrade. Zahvaljujem Festo d.o.o. na ustupanju opreme i podataka korištenih tijekom izrade ovog diplomskog rada.

SADRŽAJ

1.	UVOD.....	1
2.	METODOLOGIJA	2
2.1.	<i>Prikupljanje podataka potrebnih za treniranje modela</i>	<i>2</i>
2.1.1.	Grafički prikaz odnosa podataka koji opisuju pneumatski mišić.....	2
2.1.2.	Numerički podaci	3
2.2.	<i>Statistička analiza i obrada podataka</i>	<i>5</i>
2.3.	<i>Umjetne neuronske mreže - višeslojni perceptron</i>	<i>10</i>
2.3.1.	Aktivacijske funkcije.....	11
2.3.2.	Funkcije gubitaka	16
2.4.	<i>Implementacija modela pomoću Tensorflow Python knjižnice</i>	<i>18</i>
3.	REZULTATI MODELA	22
3.1.	<i>DMSP 5-100N tip pneumatskog mišića</i>	<i>22</i>
3.1.1.	Model za predviđanje iznosa dopuštene sile F.....	22
3.1.2.	Model za predviđanje iznosa kontrakcije nominalne duljine h.....	25
3.1.3.	Model za predviđanje iznosa tlaka p	28
3.2.	<i>DMSP 10-100N tip pneumatskog mišića</i>	<i>32</i>
3.2.1.	Model za predviđanje iznosa dopuštene sile F.....	32
3.2.2.	Model za predviđanje iznosa kontrakcije nominalne duljine h.....	35
3.2.3.	Model za predviđanje iznosa tlaka p	38
3.3.	<i>DMSP 20-200N tip pneumatskog mišića</i>	<i>41</i>
3.3.1.	Model za predviđanje iznosa dopuštene sile F.....	41
3.3.2.	Model za predviđanje iznosa kontrakcije nominalne duljine h.....	43
3.3.3.	Model za predviđanje iznosa tlaka p	46
3.4.	<i>DMSP 40-400N tip pneumatskog mišića</i>	<i>49</i>
3.4.1.	Model za predviđanje iznosa dopuštene sile F.....	49
3.4.2.	Model za predviđanje iznosa kontrakcije nominalne duljine h.....	51
3.4.3.	Model za predviđanje iznosa tlaka p	54
3.5.	<i>Skupni podaci sa svim tipovima pneumatskog mišića</i>	<i>57</i>
3.5.1.	Model za predviđanje iznosa dopuštene sile F.....	57
3.5.2.	Model za predviđanje iznosa kontrakcije nominalne duljine h.....	60
3.5.3.	Model za predviđanje iznosa tlaka p	62
4.	ZAKLJUČAK.....	65
5.	LITERATURA	66
6.	POPIS SLIKA.....	67
7.	POPIS TABLICA	70
8.	SAŽETAK I KLJUČNE RIJEČI	72
9.	ABSTRACT AND KEYWORDS	73

1. UVOD

Pneumatski mišić, još poznat i kao pneumatski umjetni mišić (*eng. Pneumatic artificial muscle*) predstavlja vrstu aktuatora korištenih u robotici, biomehanici i protetici, koji imitiraju ponašanje biološkog mišića. Kao i svaki drugi aktuator, pneumatski mišić koristi se za realizaciju određene vrste gibanja kao što je linearno ili rotacijsko gibanje. Međutim, način rada pneumatskog mišića nešto se razlikuje od klasičnog aktuatora. Pneumatski mišić obično se sastoji od fleksibilnog vanjskog pokrova, često izrađenog od gume ili drugog elastičnog materijala koji sadrži zračnu komoru u koju se upuhuje komprimirani zrak. Kada se u komoru dovede zrak ili plin pod tlakom, mišić se širi, uzrokujući njegovu uzdužnu kontrakciju. Ova kontrakcija stvara vučnu silu duž duljine mišića.

Kontroliranjem tlaka zraka unutar komore, stupanj kontrakcije i rezultirajuća snaga pneumatskog mišića mogu se precizno regulirati. Razumijevanje i precizno modeliranje ponašanja pneumatskih mišića ključno je za optimizaciju njihove izvedbe i učinkovito integriranje u različite sustave. Moguće je korištenje matematičkih modela temeljenih na fizikalnim principima, međutim takvi modeli pate od nesigurnosti koje proizlaze zbog kompleksnog nelinearnog ponašanja pneumatskih mišića. Alternativa dolazi u obliku korištenja algoritama umjetne inteligencije gdje se tehnikama strojnog učenja izrađuju prediktivni modeli koji u usporedbi s tradicionalnim vrstama modeliranja mogu postići preciznije predikcije ponašanja pneumatskih mišića.

U ovom radu, korištenjem umjetne neuronske mreže realizirat će se jedan generalni model te više popratnih modela za različite vrste pneumatskog mišića koji će na temelju ulaznih podataka predviđati vrijednosti željene izlazne veličine. Ovakvim pristupom se postiže smanjenje kompleksnosti upravljanja samog pneumatskog mišića, primjerice od strane operatora u proizvodnom pogonu.

Pneumatski mišići korišteni u ovom radu su DMSP modeli pneumatskog mišića multinacionalne robotske tvrtke FESTO. Mišić se sastoji od unutarnje gumene dijafragme, koja je okružena tkanim aramidnim vlaknima. Aramid je posebna vrsta sintetičkih vlakana visoke čvrstoće, koja ne samo da dodaje strukturni integritet aktuatoru, već također prenosi kinetičku energiju. Pneumatski mišić je dizajniran da oponaša funkcionalnost biološkog mišića za korištenje u složenoj industrijskoj automatizaciji. Tvrtka FESTO nudi više vrsta ovakvih mišića različitih specifikacija. Tako su i u svrhu regresijskog modeliranja pneumatskog mišića u ovom radu korištene četiri vrste mišića.

U nastavku rada bit će prikazan cjelokupan proces regresijskog modeliranja pneumatskog mišića korištenjem algoritama umjetne inteligencije. Prvobitno će biti izvršeno prikupljanje podataka potrebnih za strojno učenje koji će se potom statistički obraditi. Nakon što su podaci adekvatno pripremljeni za implementaciju u strojnom učenju, realizirat će se modeli umjetne inteligencije koji će opisivati ponašanje pneumatskog mišića.

2. METODOLOGIJA

U ovom poglavlju će biti opisan postupak dobivanja skupa podataka za treniranje modela. Zatim će biti opisane tehnike strojnog učenja korištene za realizaciju pojedinačnih modela, a zatim i generalnog modela za modeliranje razmatranih pneumatskih mišića.


2.1. Prikupljanje podataka potrebnih za treniranje modela

Kako bi uopće bilo moguće razviti bilo kakav model korištenjem algoritama umjetne inteligencije, potreban je određen skup podataka (*eng. Dataset*) koji će model koristiti za učenje, a kasnije i za evaluaciju. Kada se govori o učenju s učiteljem (*eng. Supervised learning*), kao što je to slučaj u ovom radu, skup podataka daje potrebne ulazno-izlazne parove koji algoritmima strojnog učenja omogućuju učenje obrazaca i odnosa među podacima, što im u konačnici omogućuje točna predviđanja ili klasifikacije na novim, dosad nepoznatim podacima. Dobar skup podataka je izuzetno bitan kako bi se dobio što bolji model. Tako na performanse modela utječu kvaliteta, kvantiteta i raznolikost podataka unutar samog skupa podataka. Upravo je ovaj proces prikupljanja potrebnih podataka prvi korak koji je potrebno izvršiti kako bi bilo moguće krenuti dalje s implementacijom modela neuronske mreže koji će opisivati razmatrani pneumatski mišić.

2.1.1. Grafički prikaz odnosa podataka koji opisuju pneumatski mišić

Podatke koji opisuju ponašanje pneumatskog mišića moguće je pronaći na službenim stranicama proizvođača. Razmatrani DMSP pneumatski mišić dostupan je u četiri varijante (za različite iznose opterećenja). Fizikalne veličine koje ga opisuju su: iznos dopuštene sile F [N], iznos kontrakcije nominalne duljine h [%] te iznos tlaka fluida unutar komore p [bar]. Ove tri veličine u potpunosti opisuju ponašanje mišića u radnim uvjetima.

Problem koji se javlja kod prikupljanja podataka o navedenim veličinama je taj što su njihovi odnosi dani grafički, odnosno u obliku dopuštene sile F [N] kao funkcije kontrakcije nominalne duljine h [%] za vrijednosti tlaka od nula do šest bara. Primjer jednog takvog grafa prikazan je na Slici 2.1.



Slika 2.1. Graf dopuštene sile $F[N]$ kao funkcije kontrakcije nominalne duljine $h[%]$ pneumatskog mišića DMSP-5-100N

Za pravilno razumijevanje i čitanje grafa, potrebno je definirati dijelove grafa. Prikazani graf prikazuje radni raspon pneumatskog mišića kao funkciju promjera, unutar određenih granica. Gornja granica sivog zone označava maksimalnu vrijednost dopuštene sile. Desna granična krivulja sivog područja označava maksimalni dopušteni radni tlak mišića. Desna okomita granica sivog područja označava maksimalnu dopuštenu kontrakciju. Lijeva granica sivog područja određuje granicu maksimalnog dopuštenog prednaprezanja mišića.

2.1.2. Numerički podaci

Budući da su modelu za učenje potrebni strukturirani numerički podaci, potrebno je podatke iz danih grafova na adekvatan način izvući te prebaciti u numeričke vrijednosti. Ovaj proces pretvorbe izvršen je korištenjem internetskog alata WebPlotDigitizer. S navedenim alatom, moguće je učitati sliku grafa te ručnim označavanjem točaka na grafu dobiti numeričke vrijednosti označenih točaka za x-os i y-os. Ovaj proces odrađen je za svaki od četiri grafa koji modeliraju četiri različita modela pneumatskog mišića. Time su dobivena četiri numerička skupa podataka te jedan veliki zajednički skup koji objedinjuje sve mišiće. Ovih pet skupova će biti korišteni u svrhu realizacije više modela umjetne neuronske mreže koji će modelirati pojedine pneumatske mišiće. Isječak iz zajedničkog generiranog skupa podataka, koji se sastoji od ukupno 5452 vrijednosti, prikazan je na Tablici 2.1.


Tablica 2.1. Zajednički skup podataka za sve modele mišića

	Model	F	h	p
0	0	31.670	-1.076	0
1	0	30.239	-1.035	0
2	0	29.284	-1.015	0
3	0	28.091	-1.015	0
4	0	27.137	-0.954	0
...
5447	3	1031.479	24.487	6
5448	3	1003.370	24.603	6
5449	3	984.695	24.765	6
5450	3	965.967	24.857	6
5451	3	947.240	24.950	6

Zajednički skup podataka se sastoji od četiri stupca značajki:

- Model pneumatskog mišića (ukupno četiri modela različitih karakteristika),
- Iznos dopuštene sile F [N],
- Iznos kontrakcije nominalne duljine h [%],
- Iznos tlaka fluida unutar komore p [bar]

Dobivene vrijednosti poželjno je vizualno prikazati kako bi se utvrdila sličnost s originalnim podacima od proizvođača. Grafički prikaz sva četiri skupa podataka za četiri različita modela DMSP pneumatskog mišića dan je na Slici 2.2. Iz danih grafova moguće je dobiti generalni uvid o ponašanju mišića za različite iznose parametara kao što su sila, kontrakcija duljine i pritisak.



Slika 2.2. Grafički prikaz podataka za različite modele pneumatskog mišića

2.2. Statistička analiza i obrada podataka

U ovom poglavlju bit će prikazani rezultati statističke analize skupa podataka dobivenog u prethodnom poglavlju. Statističku analizu podataka je nužno provesti kako bi se dobio bolji uvid u sami skup podataka, te da se detektiraju potencijalni problemi u skupu zbog kojeg bi budući modeli mogli podbaciti.

Opisna statistika prikazana u Tablici 2.2 pokazuje vrijednosti raznih statističkih parametara dobivenih za pojedinačne i zajednički skup podataka. Opisna statistika pokazuje visoku varijaciju između skupova podataka za pojedinačne pneumatske mišiće. Kao što je i očekivano, zajednički skup podataka teži srednjoj vrijednosti ostalih podataka, što upućuje na to da bi ovaj skup podataka mogao dobro predviđati vrijednosti iz ostalih skupova. Statistika je dana za vrijednosti sile F i iznosa kontrakcije h . Vrijednost tlaka p nije uzeta u obzir budući da se radi o diskretnim i konstantnim iznosima od 0 do 6 bara.

Tablica 2.2. Opisna statistika svih skupova podataka

Parametar	DMSP-5-100N		DMSP-10-100N		DMSP-20-200N		DMSP-40-400N		SKUPNO	
	h	F	h	F	h	F	h	F	h	F
Mode	-1.02	24.81	-0.61	37.26	-3.62	188.1	-3.92	57.41	-2.66	24.81
Mean	5.72	51.77	6.45	239.82	6.88	592.63	8.37	2269.35	6.96	857.49
Std	5.67	37.46	7.39	170.6	8.1	413.41	8.59	1565.64	7.71	1248.18
Skewness	0.71	0.62	0.59	0.53	0.47	0.49	0.22	0.58	0.51	2.14
Kurtosis	-0.67	-0.64	-0.78	-0.79	-0.98	-0.89	-1.13	-0.68	-0.85	4.06
Min	-1.08	1.01	-3.05	3.57	-3.92	9.75	-4.9	57.41	-4.92	1.01
Max	19.73	140.53	24.96	634.09	24.9	1495.39	25.05	6000.16	25.05	6000.16

Parametri korišteni za analizu opisani su u nastavku.

Mode je vrijednost koja se najčešće pojavljuje u skupu podataka, što ga čini korisnim za identificiranje najčešće kategorije ili vrijednosti. Neki skupovi podataka mogu imati više od jedne vrijednosti ovog parametra, poznatog kao bimodalni ili multimodalni, ili uopće nemaju *mode* vrijednost ako su sve vrijednosti jedinstvene.

Mean ili srednja vrijednost je aritmetički prosjek svih vrijednosti u skupu podataka, izračunat zbrajanjem svih vrijednosti i dijeljenjem s brojem vrijednosti. Ona predstavlja središnju točku skupa podataka, ali može biti pod utjecajem ekstremnih vrijednosti, također poznatih kao ekstremi (eng. *outliers*).

Std ili standardna devijacija mjeri količinu varijacije ili disperzije u skupu vrijednosti. Ona pokazuje koliko su vrijednosti raširene oko sredine. Niska standardna devijacija znači da su vrijednosti blizu sredine, dok visoka standardna devijacija znači da su vrijednosti više raširene.

Skewness ili iskrivljenost je mjera asimetrije distribucije. Distribucija je asimetrična kada njena lijeva i desna strana nisu zrcalne slike. Distribucija može imati desnu (pozitivnu), lijevu (negativnu) ili nultu asimetriju.


Kurtosis je parametar koji mjeri zaokruženost distribucije. Zaokruženost opisuje koliko se često pojavljuju odstupanja.

Minimalna vrijednost je najmanja vrijednost u skupu podataka, što označava donju granicu skupa, dok je maksimalna vrijednost najveća vrijednost u skupu, odnosno gornja granica skupa.


Prilikom izvršavanja statističke analize podataka, važno je pravilno identificirati korelaciju između razmatranih podataka. Korelacija podataka važan je pojam u analizi podataka. Ona kvantificira snagu i smjer odnosa između dvije varijable, omogućujući bolje razumijevanje kako promjene u jednoj varijabli mogu biti povezane s promjenama u drugoj. Ovo razumijevanje ključno je za prepoznavanje obrazaca, izradu predikcija i otkrivanje potencijalnih uročnih odnosa. Analizom korelacije moguće je poboljšati točnost modela, otkriti multikolinearnost i donositi informiranije odluke. Osim toga, analiza korelacije može naglasiti važne uvide i potaknuti daljnja istraživanja temeljenim na promatranim podacima.

Na donjim slikama prikazane su četiri korelacijske matrice, svaka za jedan model razmatranog pneumatskog mišića. Kroz prikazane matrice može se primijetiti blaga pozitivna korelacija između kontrakcije nominalne duljine h i tlaka p . Isto tako, moguće je primijetiti i nešto veće iznose negativne korelacije između sile F i kontrakcije nominalne duljine h . Korelacije su posebno niske za izlaznu veličinu tlaka p .


Zaključno, iako postoji određena korelacija između ciljanih vrijednosti, ti iznosi nisu dovoljno visoki da bi upućivali na znatniju korelaciju između razmatranih veličina.




Slika 2.3. Korelacijska matrica za DMSP-5-100N



Slika 2.4. Korelacijska matrica za DMSP-10-100N




Slika 2.5. Korelacijska matrica za DMSP-20-200N



Slika 2.6. Korelacijska matrica za DMSP-40-400N


Korelaciju podataka moguće je usporediti i za zajednički skup podataka. Korelacijska matrica za zajednički skup podataka prikazana je na Slici 2.7. Zajedno sa standardnim promatranim veličinama iznosa sile, kontrakcije i tlaka, u razmatranje korelacije zajedničkog skupa uključeni su i dodatni podaci o mišićima. Ovi dodatni podaci neće biti korišteni u daljnjoj realizaciji modela budući da se radi o konstantnim podacima. Baš kao kod pojedinačnih skupova podataka, može se zaključiti kako nema visokih iznosa korelacije među izlaznim veličinama.




Slika 2.7. Korelacija podataka u zajedničkom skupu podataka

Slijedeći važan pojam u statističkoj analizi je distribucija podataka. Distribucija podataka važna je u analizi iz razloga što pruža uvid u rasprostranjenost i oblik podataka, time pridonoseći boljem razumijevanju temeljnih obrazaca i sklonosti podataka. Poznavanje distribucije omogućuje točnije statističko modeliranje, testiranje hipoteza i identifikaciju iznimaka, što na kraju dovodi do pouzdanijih zaključaka i boljeg donošenja odluka. Osim toga, razumijevanje distribucije pomaže u odabiru prikladnih statističkih testova i modela, budući da mnoge statističke metode pretpostavljaju određenu vrstu distribucije podataka. Također pomaže u otkrivanju bilo kakve iskrivljenosti (eng. *kurtosis*) u podacima, što može dodatno informirati prilagodbe ili transformacije potrebne za ispunjavanje pretpostavki analize.


U nastavku su Slikama 2.8 do 2.17 dani histogrami koji prikazuju distribuciju podataka sile i kontrakcije u pojedinačnim skupovima te u zajedničkom skupu. Usprkos velikoj količini podataka, u skupovima je prisutna određena doza iskrivljenosti (eng. *skewness*) podataka od normalne distribucije. Ova iskrivljenost bi mogla ukazivati na moguće probleme kod rezultirajućih modela.




Slika 2.8. Histogram sile za DMSP-5-100N




Slika 2.9. Histogram sile za DMSP-10-100N




Slika 2.10. Histogram sile za DMSP-20-200N




Slika 2.11. Histogram sile za DMSP-40-400N




Slika 2.12. Histogram sile za zajednički skup




Slika 2.13. Histogram kontrakcije za DMSP-5-100N




Slika 2.14. Histogram kontrakcije za DMSP-10-100N



Slika 2.15. Histogram kontrakcije za DMSP-20-200N



Slika 2.16. Histogram kontrakcije za DMSP-40-400N




Slika 2.17. Histogram kontrakcije za zajednički skup

2.3. Umjetne neuronske mreže - višeslojni perceptron

Za regresijsko modeliranje pneumatskog mišića, koristit će se algoritmi umjetne inteligencije, točnije, neuronske mreže. Umjetne neuronske mreže su podskup strojnog učenja koje su dizajnirane da simuliraju način na koji ljudski mozak obrađuje informacije. Sastoje se od slojeva međusobno povezanih čvorova, ili neurona. Kroz proces treniranja mogu učiti složene obrasce u podacima. Tijekom treniranja, mreža prilagođava težine veza na temelju ulaznih podataka i željenog izlaza, minimizirajući razliku između predviđenih i stvarnih rezultata.

Višeslojni perceptron (eng. *Multilayer perceptron*, *MLP*) je model umjetne neuronske mreže koji se sastoji od najmanje tri sloja: ulaznog sloja, više od jednog skrivenog sloja i izlaznog sloja [1]. Karakteristika višeslojnog perceptrona je ta da je svaki čvor u jednom sloju povezan sa svakim čvorom u sljedećem sloju, ali ne i sa čvorovima unutar sloja ili prema natrag. Ulazni sloj prima ulazne podatke, pri čemu svaki čvor predstavlja značajku ulaznih podataka. Skriveni slojevi izvode nelinearne transformacije ulaznih podataka, omogućujući mreži da uči složene obrasce. Izlazni sloj proizvodi konačni izlaz mreže, pri čemu broj čvorova odgovara broju željenih izlaza. Arhitektura višeslojnog perceptrona prikazana je na Slici 2.18.




Slika 2.18. Arhitektura višeslojnog perceptrona [2]

Neuroni unutar mreže uče kroz proces treniranja ili učenja. Na početku, svim neuronima u mreži dodijeljene su slučajne težine w (eng. *weight*) povezane s njihovim ulazima. Težine predstavljaju brojeve koji određuju koliko je svaki ulaz važan za dan neuron. Ulazni podaci se prosljeđuju kroz mrežu od ulaznog sloja, preko skrivenih slojeva, do izlaznog sloja. Svaki neuron prima ulaze, množi ih s pripadajućim težinama, zbraja te vrijednosti, dodaje faktor pristranosti (eng. *bias*) i primjenjuje aktivacijsku funkciju čime se proizvodi izlaz. Ovaj proces se ponavlja za svaki neuron u svakom sloju mreže. Grafički prikaz ovog procesa je prikazan Slikom 2.19. Jednadžba procesa je dana prema:

$$z = \sigma \left(\sum_{i=1}^N x_i w_i + b \right), \quad 2.1$$

gdje x_i predstavlja ulazne značajke, w_i težine povezane s ulaznim značajkama, b faktor pristranosti, $\sigma(x)$ aktivacijsku funkciju te z izlaz iz neurona.



Slika 2.19. Proces učenja neurona unutar mreže [3]

Nakon što mreža proizvede izlaz, taj se izlaz uspoređuje s ciljnim (željenim) izlazom koristeći funkciju gubitaka (eng. *Loss function*), koja mjeri koliko je mrežin izlaz različit od ciljanog izlaza. O funkcijama gubitaka više u nastavku. Pogreška se propagira unatrag kroz mrežu kako bi se ažurirale težine. Ovaj proces se izvodi računajući gradijentne pogreške s obzirom na težine koristeći lančano pravilo diferencijacije. Gradijenti pokazuju smjer i veličinu promjene koja je potrebna za smanjenje pogreške.

Težine se zatim ažuriraju koristeći gradijente i algoritam optimizacije, najčešće gradijentni spust (eng. *Gradient descent*). Svaka težina se prilagođava u smjeru koji smanjuje pogrešku, a brzina te prilagodbe kontrolira se hiperparametrom koji se zove stopa učenja (eng. *learning rate*). Ovi koraci, uključujući prosljeđivanje naprijed, izračunavanje pogreške, širenje pogreške unatrag i ažuriranje težina, ponavljaju se kroz mnogo iteracija i epoha sve dok mreža ne postigne zadovoljavajuću razinu točnosti ili dok pogreška ne postane dovoljno mala.

Kroz ovaj proces, neuroni unutar mreže uče prilagoditi svoje težine kako bi mreža mogla precizno predviđati izlaze na temelju ulaznih podataka. Na taj način, mreža uči složene obrasce i odnose u podacima, omogućujući joj da generalizira i daje točne predikcije na novim, neviđenim podacima.

2.3.1. Aktivacijske funkcije


U procesu treniranja neuronske mreže, odnosno učenju, aktivacijske funkciju imaju veliku ulogu. Aktivacijske funkcije uvode nelinearnost u neuronske mreže, što je ključno za njihovu sposobnost modeliranja složenih odnosa u podacima. Bez aktivacijskih funkcija, svaki sloj neuronske mreže izvodio bi samo linearnu transformaciju svojih ulaza. To bi značilo da bi cijela mreža, bez obzira na njenu dubinu, bila ekvivalentna jednom sloju koji izvodi linearnu transformaciju. Ovo bi ozbiljno ograničilo sposobnost mreže da modelira složene, nelinearne odnose u podacima.

Aktivacijske funkcije primjenjuju nelinearnu operaciju na ponderiranu sumu ulaza na svakom neuronu. Ova nelinearna transformacija omogućuje mreži da aproksimira nelinearne funkcije i uhvati složenije obrasce u podacima. Upravo je uvođenje ove nelinearnosti ono što daje neuronskim mrežama njihovu teorijsku sposobnost aproksimacije bilo koje kontinuirane funkcije.

Nelinearne aktivacijske funkcije također igraju ulogu u povratnom širenju (eng. Backpropagation) pružajući gradijente različite od nule koji omogućuju mreži učenje putem gradijentnog spusta. Ovom nelinearnošću je omogućeno mreži učenje iz složenih podataka koji često pokazuju nelinearne odnose u primjerima iz stvarnog svijeta. Upravo je to slučaj i za pneumatske mišiće. U nastavku su prikazane i opisane neke od najčešće korištenih aktivacijskih funkcija korištenih kod modeliranja neuronskih mreža, a ujedno i kod regresijskog modeliranja pneumatskog mišića razmatranog u ovom radu.

Linearna funkcija

Linearna, također poznata i kao identitetska aktivacijska funkcija predstavlja najosnovniji tip aktivacijske funkcije. Matematički izraz definiran je Jednadžbom 2.2, gdje se jasno vidi kako ova funkcija na izlazu jednostavno vraća ulaznu vrijednost bez ikakve transformacije. Njezina derivacija je uvijek 1, što može biti korisno za protok gradijenta, ali ne uvodi nikakvu nelinearnost u mrežu. Prednost ovakve aktivacijske funkcije je ta da je računarski učinkovita jer ne zahtjeva složene izračune. Korisna je za zadatke koji su inherentno linearni i često se koristi u izlaznom sloju za regresijske probleme. Međutim, ograničenje ovakve funkcije je nemogućnost učenja složenih obrazaca niti predstavljanja nelinearnih funkcija. Mogućnosti neuronskih mreža uvelike proizlaze iz njihovih sposobnosti predstavljanja nelinearnih funkcija, što zahtjeva nelinearne aktivacijske funkcije u skrivenim slojevima. Upravo zbog toga, linearna aktivacijska funkcija se ne koristi u skrivenim slojevima neuronskih mreža. Grafički prikaz linearne aktivacijske funkcije dan je na Slici 2.20.




Slika 2.20. Linearna (identitetska) aktivacijska funkcija

Jednadžba linearne funkcije je dana prema:

$$f(x) = x. \quad 2.2$$

Sigmoidna funkcija

Sigmoidna funkcija sažima ulazne vrijednosti u rasponu od 0 do 1, što je čini korisnom za izlaze koji predstavljaju vjerojatnosti. Upravo se zbog toga često koristi u izlaznom sloju kod problema binarne klasifikacije. Međutim, njezina upotreba u skrivenim slojevima se smanjila zbog problema nestajućeg gradijenta, gdje gradijenti postaju vrlo mali za velike ulazne magnitude, time usporavajući učenje mreže. Primjena ove aktivacijske funkcije se pronalazi kod binarne klasifikacije i logističke regresije. Grafički prikaz sigmoidne aktivacijske funkcije je dan na Slici 2.21.




Slika 2.21. Sigmoidna aktivacijska funkcija

Jednadžba sigmoidne funkcije je dana prema:

$$f(x) = \frac{1}{1 + e^{-x}} \quad 2.3$$

Hiperbolički tangens (tanh)

Aktivacijska funkcija hiperbolički tangens je slična sigmoidnoj funkciji, međutim razlika je u rasponu vrijednosti koje daje na izlazu. Hiperbolički tangens na izlazu daje raspon vrijednosti od -1 do 1, što ovoj funkciji omogućuje bolje djelovanje kod negativnih vrijednosti. Centrirana je oko nule, što može pomoći u konvergenciji mreže. Baš kao i kod sigmoidne funkcije, kod hiperboličkog tangensa dolazi do problema nestajućih gradijenata, ali u manjoj mjeri. Ova aktivacijska funkcija pronalazi svoju primjenu u povratnim neuronskim mrežama za zadatke poput obrade prirodnog jezika. Grafički prikaz aktivacijske funkcije hiperboličkog tangensa dan je na Slici 2.22.




Slika 2.22. Aktivacijska funkcija hiperbolički tangens

Jednadžba funkcije hiperboličkog tangensa je dana prema:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}. \quad 2.4$$

ReLU

ReLU (*Rectified Linear Unit*) aktivacijska funkcija jedna je od najpopularnijih aktivacijskih funkcija za mnoge vrste neuronskih mreža. Računarski je učinkovita i pomaže u ublažavanju problema nestajućeg gradijenta. Međutim, može patiti od problema gdje neuroni mogu zapeti na izlazu nula za sve ulaze. Neke od praktičnih primjena ove funkcije su u konvolucijskim neuronskim mrežama za prepoznavanje slika te u dubokim neuronskim mrežama za razne zadatke. Upravo je ReLU aktivacijska funkcija prvenstveno korištena u ovom radu u realizaciji višeslojnog perceptrona za regresijsko modeliranje pneumatskog mišića. Grafički prikaz ReLU aktivacijske funkcije je dan na Slici 2.23.




Slika 2.23. ReLU aktivacijska funkcija

Jednadžba ReLU funkcije je dana prema:

$$f(x) = \max(0, x). \quad 2.5$$

Propusna ReLU

Kod ReLU funkcije spomenut je problem gdje neuroni mogu zapeti na izlazu nula za sve ulaze, tzv. problem „umirujuće ReLU“. Propusna ReLU aktivacijska funkcija upravo pokušava riješiti ovaj problem dopuštajući male negativne vrijednosti kada je izlaz manji od nule. Ta mala doza propuštanja za negativne vrijednosti definirana je faktorom a koji pomnožen s vrijednošću funkcije daje mali otklon od nule. Ovo može pomoći u održavanju određenog gradijenta čak i za negativne ulaze, potencijalno poboljšavajući učenje. Praktične primjene ove funkcije ju uključuju kao zamjenu za klasičnu ReLU aktivacijsku funkciju u arhitekturama gdje se pojavljuje gore navedeni problem. Grafički prikaz propusne ReLU funkcije dan je na Slici 2.24.



Slika 2.24. Propusna ReLU aktivacijska funkcija

Jednadžba propusne ReLU funkcije je dana prema:

$$f(x) = \begin{cases} x, & x \geq 0 \\ ax, & x < 0 \end{cases} \quad 2.6$$

Osim gore navedenih aktivacijskih funkcija, u arhitekturama neuronskih mreža se još korite i druge aktivacijske funkcije poput Eksponencijalne linearne jedinice, Binarna step funkcija, parametarska ReLU i dr.

2.3.2. Funkcije gubitaka

Kako bi neuronske mreže bile u stanju učiti, moraju biti u stanju uspoređivati trenutni izlaz iz mreže sa stvarnim, željenim izlazom. Upravo je to zadatak funkcija gubitaka. Funkcije gubitaka predstavljaju ključnu komponentu neuronskih mreža gdje kvantificiraju razliku između predviđenih izlaza i stvarnih ciljanih vrijednosti. Tijekom treniranja mreže, algoritmi optimizacije, poput gradijentnog spusta, koriste generirane vrijednosti funkcije gubitaka za ažuriranje težina unutar mreže. Na taj način, funkcija gubitaka vodi proces učenja i pomaže mreži da se bolje prilagodi podacima.

Funkcija gubitaka pruža jasnu metriku za evaluaciju performansi modela. Niske vrijednosti funkcija gubitaka impliciraju da model dobro predviđa ciljane vrijednosti, dok visoka vrijednost sugerira potrebu za daljnjim prilagođavanjem modela.

Tijekom treniranja, funkcija gubitaka pruža informativnu povratnu informaciju o tome koliko se model poboljšava s obzirom na preciznost i generalizaciju. Ova povratna informacija je ključna za prilagođavanje hiperparametara, arhitekture mreže i strategija treniranja kako bi se postigla optimalna izvedba.

Funkcije gubitaka mogu se podijeliti na dvije vrste, s obzirom na vrstu problema koji se razmatra. Mogu biti regresijskog i klasifikacijskog karaktera. Budući da se tematika ovog rada bazira na regresijskom problemu, u nastavku su prikazane i opisane neke od regresijskih funkcija gubitaka korištenih u radu.

Srednja apsolutna pogreška

Srednja apsolutna pogreška (eng. *Mean Absolute Error, MAE*) mjeri prosječnu apsolutnu razliku između predviđenih vrijednosti i stvarnih, ciljanih vrijednosti. Računa se kao prosjek apsolutnih vrijednosti razlika između predviđenih i stvarnih vrijednosti. Često se koristi u regresijskim zadacima jer pruža vrlo jednostavnu i intuitivnu metriku koja jasno pokazuje koliko su predikcije daleko od stvarnih vrijednosti. Jedna od glavnih prednosti ove metrike je njezina robusnost prema ekstremima (eng. *outliers*) iz razloga što jednako tretira sve pogreške, bez obzira na njihovu veličinu. Međutim, jedan od nedostataka je što ne daje informacije o varijaciji pogrešaka, što može biti važno u nekim aplikacijama. Srednja apsolutna pogreška se definira prema jednadžbi:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|. \quad 2.7$$

Srednja kvadratna pogreška

Srednja kvadratna pogreška (eng. *Mean Squared Error, MSE*) mjeri prosječnu kvadratnu razliku između predviđenih vrijednosti i stvarnih vrijednosti. Računa se kao prosjek kvadrata razlika između predviđenih i stvarnih vrijednosti. Srednja kvadratna pogreška je vrlo popularna funkcija gubitka za regresijske zadatke iz razloga što kažnjava veće pogreške više nego manje pogreške, što može pomoći modelu da bude precizniji u predikcijama. Prednost joj je njezina osjetljivost na velike pogreške, što može poboljšati točnost modela. S druge strane, ova osjetljivost na velike pogreške može biti i nedostatak ako skup podataka sadrži ekstreme koji mogu prekomjerno utjecati na vrijednost gubitka. Srednja kvadratna pogreška se definira prema jednadžbi:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2. \quad 2.8$$

Korijen srednje kvadratne pogreške

Korijen srednje kvadratne pogreške (eng. *Root mean Squared Error, RMSE*) mjeri prosječnu veličinu pogreške na isti način kao srednja kvadratna pogreška, ali ključna razlika je ta da su rezultati u istim mjernim jedinicama kao i stvarne vrijednosti, što može uvelike olakšati interpretaciju pogreške. Korijen srednje kvadratne pogreške je često korišten u situacijama gdje je važno imati metriku koja je u istim jedinicama kao i ciljne vrijednosti, primjerice u vremenskim serijama podataka i predikcijama kontinuiranih vrijednosti. Glavna prednost mu je što kombinira prednosti srednje kvadratne pogreške dok održava jedinice mjerenja konzistentnima. Međutim, i on može biti previše osjetljiv na ekstreme u skupu podataka. Korijen srednje kvadratne pogreške se definira prema jednadžbi:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}. \quad 2.9$$

Srednja apsolutna postotna pogreška

Srednja apsolutna postotna pogreška (eng. *Mean Absolute Percentage Error, MAPE*) mjeri prosječnu apsolutnu postotnu pogrešku između predviđenih i stvarnih vrijednosti. Računa se kao prosjek apsolutnih postotnih razlika između predviđenih i stvarnih vrijednosti. Posebno je koristan u poslovnim aplikacijama i ekonomiji gdje je važan postotni odnos pogrešaka. Prednost mu je što pruža jasnu interpretaciju pogrešaka u postotcima, što može biti intuitivno za mnoge korisnike. Međutim, glavni nedostatak je taj što može biti problematičan kod vrijednosti koje su blizu nule, jer može rezultirati vrlo visokim postotnim pogreškama. Upravo će se ovaj nedostatak pokazati u određenim primjerima rezultata modela u ovom radu. Srednja apsolutna postotna pogreška se definira prema jednadžbi:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i} \cdot 100\%. \quad 2.10$$

2.4. Implementacija modela pomoću Tensorflow Python knjižnice

TensorFlow je knjižnica otvorenog koda koju je razvio Google Brain tim, prvenstveno za primjenu u strojnome učenju i dubokom učenju. Od svog izlaska 2015. godine, postala je jedna od najpopularnijih i najšire korištenih alata u području umjetne inteligencije. Fleksibilnost, skalabilnost i opsežna podrška zajednice čine TensorFlow preferiranim izborom kako za istraživačke, tako i za produkcijske okoline. TensorFlow podržava razne zadatke strojnog učenja, od jednostavnih modela linearne regresije do složenih arhitektura dubokog učenja poput konvolucijskih neuronskih mreža, rekurentnih neuronskih mreža i dr. TensorFlow može raditi na više procesorskih i grafičkih jezgri, što ga čini prikladnim za zadatke velikih razmjera strojnog učenja. Podržava distribuirano računanje, omogućujući treniranje na mnogim strojevima i uređajima, što je ključno za rukovanje velikim količinama podataka i složenim modelima. Sveobuhvatan skup alata, skalabilnost i podrška zajednice čine TensorFlow moćnom i svestranom knjižnicom za primjene strojnog učenja i dubokog učenja.

U nastavku će biti detaljno opisan provedeni postupak implementacije modela za predikciju iznosa sile na primjeru skupa podataka za DMSP-5-100N tip mišića.

Na početku je potrebno učitati sve knjižnice koje će se koristiti dalje u kodu. To uključuje knjižnice kao što su TensorFlow, Pandas, Numpy, Matplotlib, Seaborn i dr. Isto tako, ponekad je poželjno, umjesto učitavanja kompletne knjižnice, iz pojedinih knjižnica učitati samo elemente koji će biti potrebni u trenutnom kodu. Time se postižu određene pogodnosti kao što su bolja memorijska efikasnost, poboljšana čitljivost, izbjegavanje sukoba u imenima varijabli i funkcija, brže učitavanje itd.

```
# imports
import tensorflow as tf
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns

from sklearn.model_selection import train_test_split
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from tensorflow.keras.optimizers import Adam
```

Funkcijom `read_csv` iz Pandas knjižnice moguće je učitati lokalno spremljenu CSV datoteku koja sadrži razmatrani skup podataka s kojim će se nastavno raditi. Učitani podaci spremljeni su u varijablu `data` tipa `pandas.DataFrame`. Ovaj tip podataka je izuzetno pogodan kod primjena u analizi podataka i strojnom učenju zbog svog tabelarnog oblika spremanja i prikaza podataka.

```
data = pd.read_csv('../../00 data/01 OP_DMSP-5-100N/OP_DMSP-5-100N.csv')
```

Nakon učitavanja skupa podataka, idući korak se odnosi na podjelu podataka na značajke X i na oznake y . Značajke predstavljaju ulazne varijable koje model koristi za donošenje predikcija. One predstavljaju informacije iz kojih model uči obrasce. Oznake su izlazne varijable ili ciljevi koje model pokušava predvidjeti. One su zapravo odgovori koje model treba proizvesti kada dobije nove podatke. Ovo je osnovni korak u procesu učenja. Model treba razumjeti odnos između značajki i oznaka. Razdvajanjem tih dvaju elemenata, model se može trenirati na značajkama kako bi točno predvidio oznake.

```
X = data[["h", "p"]]
y = data["F"]
```

Podatke značajki i oznaka je potrebno daljnje podijeliti u skupove za trening i testiranje. Podaci za trening predstavljaju podskup podataka koji se koristi za treniranje modela. Model uči obrasce i odnose između značajki i oznaka koristeći ove podatke. Testni podaci predstavljaju podskup podataka koji se koristi za procjenu performansi modela. Pomaže u procjeni koliko dobro model generalizira za nove, neviđene podatke. Ovaj korak podjele podataka na podatke za treniranje i testiranje je potrebno provesti kako bi se izbjegao problem prenaučivosti (*eng. Overfitting*). Ukoliko se model trenira i testira na istim podacima, model može naučiti šum i specifične detalje u podacima za trening, što vodi do prenaučivosti. To znači da će model dobro raditi na trening podacima, ali loše na novim podacima. Isto tako, testni podaci omogućuju kvalitetnu procjenu performansi modela na neviđenim podacima, pružajući realnu mjeru koliko će dobro raditi u stvarnome svijetu te je osigurana doza generalizacije modela. Funkcija `train_test_split` iz Scikit-learn knjižnice omogućuje jednostavnu podjelu podataka u četiri skupine. Po dvije skupine podataka značajki i oznaka za treniranje i testiranje.

```
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3)
```

Podaci su sada spremni te se može krenuti u fazu realizacije samog modela. Model se prvo inicijalizira koristeći `Sequential` klasu iz TensorFlow knjižnice. Ovakav tip modela omogućava slaganje linearnih slojeva jednog za drugim. Time je inicijaliziran prazan model koji se dalje popunjava. Funkcijom `add` moguće je pridodavanje novih slojeva modelu. Prilikom pozivanja funkcije potrebno je definirati vrstu sloja koji se dodaje. U ovom slučaju, budući da se radi o višeslojnom perceptronu koji ima sve slojeve potpuno povezane, koristi se `Dense` sloj. Kao što i samo ime govori, ovaj sloj sadrži neurone koji su potpuno povezani s neuronima u prethodnom sloju. Prilikom pridodavanja sloja modelu, sloju je potrebno definirati određene parametre kao što su broj neurona u sloju, aktivacijska funkcija, te ulazni oblik ukoliko se radi o prvom sloju modela. Tako je primjerice prvi sloj koji čini ovaj model definiran kao potpuno povezani sloj, sastoji se od 64 neurona, koristi ReLU aktivacijsku funkciju, te definira dvostruki ulazni tip podataka. Idući sloj sastoji se od 32 neurona te također koristi ReLU aktivacijsku funkciju. Posljednjim slojem modela definira se izlazna struktura. Odnosno, broj neurona definira broj izlaznih podataka koje model predviđa. U ovom slučaju, model regresijski predviđa jednu izlaznu varijablu te je stoga broj neurona u zadnjem sloju jednak jedinici. Osim ovih parametara, postoje i još niza drugih parametara kojima je moguće detaljnije specificiranje samog sloja i modela, međutim ovi su neki od glavnih parametara koji se uglavnom koriste.

```
model = Sequential()
model.add(Dense(64, activation="relu", input_shape=(2,)))
model.add(Dense(32, activation="relu"))
model.add(Dense(1))
```

Nakon popunjavanja praznog modela slojevima, moguće je pristupiti kompiliranju samog modela. Funkcijom *compile* model se kompilira, time ga pripremajući za treniranje. Ovoj funkciji mogu se pridijeliti određeni argumenti kao što su tip optimizatora, funkcija gubitaka te niz metrika. Tako je za optimizator odabran Adam (*Adaptive Moment Estimation*) optimizator. On predstavlja iterativni algoritam optimizacije koji se koristi za minimiziranje funkcije gubitaka tijekom treniranja neuronske mreže. Adam predstavlja kombinaciju RMSprop algoritma i Stohastičkog gradijentnog spusta s momentom. Važan parametar koji mu se pridodaje pri inicijalizaciji je stopa učenja (eng. *Learning rate*). Stopa učenja određuje koliko se parametri težina unutar mreže mogu mijenjati unutar konteksta optimizacije uz minimiziranje funkcije gubitaka. Prema tome, ovaj parametar je iznimno važan za samu optimizaciju i funkciju gubitaka. Osim tipa optimizatora, funkciji za kompiliranje se pridodaju i parametri funkcije gubitaka i metrike. Funkcijom gubitaka se definira prema kojem kriteriju se model ocjenjuje u postupku treniranja. Ovdje je korištena srednja kvadratna pogreška kao funkcija gubitaka. Parametrom *metrics* moguće je dodati niz raznih metrika koje će se uz funkciju gubitaka pratiti tijekom procesa treniranja modela, međutim oni neće utjecati na sam proces treniranja i ažuriranja parametara težina.

```
optimizer = Adam(learning_rate=0.001)
metrics = ['mean_absolute_error', 'mean_absolute_percentage_error']

model.compile(optimizer=optimizer, loss="mean_squared_error", metrics=metrics)
```

Nakon što je model kompiliran, moguće je pokrenuti postupak treniranja pomoću funkcije *fit*. Funkciji se pridodaju podaci za treniranje u obliku značajki i oznaka. Definira se broj epoha. Jedna epoha predstavlja jedna puni prolaz kroz skup podataka za učenje. Tako, ukoliko je definirano 100 epoha, model će proći ukupno 100 puta kroz cjelokupni skup podataka u procesu učenja. Parametar *batch_size* odnosi se na broj uzoraka podataka obrađenih zajedno u jednom potezu tijekom treniranja. Veći iznos ovog parametra znači da model obrađuje više podataka odjednom, što može ubrzati obuku, ali zahtjeva više memorije. Određeni udio pridijeljenih podataka za treniranje moguće je alocirati za potrebe validacije tijekom učenja. Time se paralelno uspoređuje točnost na podacima na kojim se konstantno trenira te na podacima kojima se vrši validacija u procesu treniranja. Važno je istovremeno pratiti ove dvije veličine. Ukoliko se iznosi ove dvije vrijednosti počnu značajno udaljavati jedna od druge, vrlo je vjerojatno došlo do prenaučavanja (eng. *Overfitting*). U tom je slučaju potrebno redefinirati model kako bi se izbjegla ova pojava. Rezultat treniranja sprema se u varijablu *model_history* kroz koju je moguće kasnije dohvatiti određene parametre treniranja koji bi mogli biti korisni. Pokretanjem ove linije koda, započinje treniranje modela. Na vrijeme izvršavanja postupka treniranja utječu svi prethodno navedeni parametri. Nakon treniranja modela, model je moguće i lokalno spremiti na računalo kako bi se poslije naknadno mogao jednostavno učitati bez potrebe za ponovnim treniranjem. Upravo je to učinjeno za svaki istrenirani model u ovom radu.

```
model_history = model.fit(X_train, y_train, epochs=100, batch_size=64,
validation_split=0.3)
```

Ovime je završen proces stvaranja modela višeslojnog perceptrona. Ovdje je prikazan postupak realizacije modela za predikciju iznosa dopuštene sile F za DMSP-5-100N model mišića. Postupak se ponavlja za svaki od četiri modela mišića te za skupni set podataka sa svim modelima mišića. Za svaku skupinu se radi po jedan model za predikciju sile F , kontrakciju h te tlak p što ukupno čini 15 različitih istreniranih modela. Postupak kod skupnog seta podataka je gotovo identičan opisanom, uz par malih razlika. Uz standardne dvije značajke, postoji i treća značajka koja označuje tip modela mišića. Isto tako, budući da se radi o većem skupu podataka od pojedinačnih skupova korištenih za posebne modele mišića, model neuronske mreže je nešto složeniji, odnosno sastoji se od više slojeva sa više neurona. Primjer jedne arhitekture modela za skupni set podataka dan je u sljedećem isječku koda. Sada je parametar ulaznog oblika veličine 3, budući da postoji dodatna značajka modela mišića. Isto tako, broj skrivenih slojeva je veći te broj neurona u pojedinim slojevima je veći.

```
model = Sequential()

model.add(Dense(128, activation="relu", input_shape=(3,)))
model.add(Dense(128, activation="relu"))
model.add(Dense(128, activation="relu"))
model.add(Dense(128, activation="relu"))
model.add(Dense(128, activation="relu"))
model.add(Dense(1))
```

Kako bi se dobio uvid u performanse modela, moguće je izvršiti evaluaciju na testnim podacima. Kao što je već rečeno, ovi podaci predstavljaju nove, dosad modelu neviđene podatke nad kojima se vrši testiranje rada modela. Funkcijom *evaluate* izvršava se evaluacija treniranog modela. Funkciji se kao argumenti daju podaci značajki i podaci oznaka. Ovdje je izvršena evaluacija performansi modela na podacima za treniranje i posebno na podacima za testiranje. Time se dobiva generalni dojam o stvarnim performansama modela. Rezultate evaluacije *evaluate* funkcijom moguće je iskoristiti za dobivanje iznosa metrika prethodno definiranih u funkciji *compile* prethodno treniranju modela. Prvo mjesto u tom nizu zauzima definirana funkcija gubitaka, u ovom slučaju srednja kvadratna pogreška. Drugo mjesto srednja apsolutna pogreška. Te posljednje mjesto srednja apsolutna postotna pogreška. Time su dobiveni numerički parametri kojima je moguće prikazati točnost rada modela.

```
eval_results_train = model.evaluate(X_train, y_train, verbose=0)
eval_results_test = model.evaluate(X_test, y_test, verbose=0)

train_mse = eval_results_train[0]
train_mae = eval_results_train[1]
train_mape = eval_results_train[2]

test_mse = eval_results_test[0]
test_mae = eval_results_test[1]
test_mape = eval_results_test[2]
```

Svi numerički rezultati, zajedno s pripadajućim vizualizacijskim rezultatima biti će prikazani u poglavljima koje slijede.

3. REZULTATI MODELA

U poglavljima koji slijede, biti će prikazani rezultati svakog odrađenog modela neuronske mreže za regresijsko modeliranje pneumatskog mišića. Prikazani će biti numerički rezultati dobiveni evaluacijom nad podacima namijenjenim za testiranje. Regresijski numerički pokazatelji točnosti modela korištenih u evaluaciji su redom: Srednja apsolutna pogreška (MAE), Srednja kvadratna pogreška (MSE), Korijen srednja kvadratne pogreške (RMSE) i Srednja apsolutna postotna pogreška (MAPE). Također, bit će prikazani i razni vizualizacijski rezultati kojima se dobiva stječe jasniji i intuitivniji uvid u same performanse razmatranog modela. Kao što je već rečeno u prethodnim poglavljima, realizirana su po tri modela neuronske mreže za svaki od četiri tipova pneumatskih mišića. Isto tako, odrađen je i model na skupnim podacima koji sadrži sve tipove pneumatskih mišića unutar jednog skupa podataka.

3.1. DMSP 5-100N tip pneumatskog mišića

DMSP-5-100N predstavlja prvi, i ujedno najmanji model razmatranih FESTO pneumatskih mišića. Karakteriziraju ga manje vrijednosti iznosa sile te je ujedno i namijenjen primjenama gdje velike sile nisu potrebne. Za pneumatski mišić realizirana su tri regresijska modela: predikcija iznosa sile, kontrakcije nominalne duljine te iznosa tlaka. U nastavku su prikazani rezultati dobivenih modela.

3.1.1. Model za predviđanje iznosa dopuštene sile F

Tablicom 3.1 prikazana je arhitektura modela višeslojnog perceptrona za predikciju iznosa sile F za DMSP-5-100N model pneumatskog mišića. Model se sastoji od ulaznog sloja s dva neurona, što ujedno predstavlja dva tip ulaznih značajki, dva skrivena sloja te izlaznog sloja s jednim neuronom. Dva skrivena sloja se sa stoje od 64 i 32 neurona, redom. Stopa učenja Adam optimizatora iznosi 0.001. Aktivacijska funkcija je ReLU. Za funkciju gubitaka odabrana je srednja kvadratna pogreška. Model je treniran kroz 100 epoha s veličinom serije podataka 64.

Tablica 3.1. Arhitektura modela za predikciju sile F za DMSP-5-100N model mišića

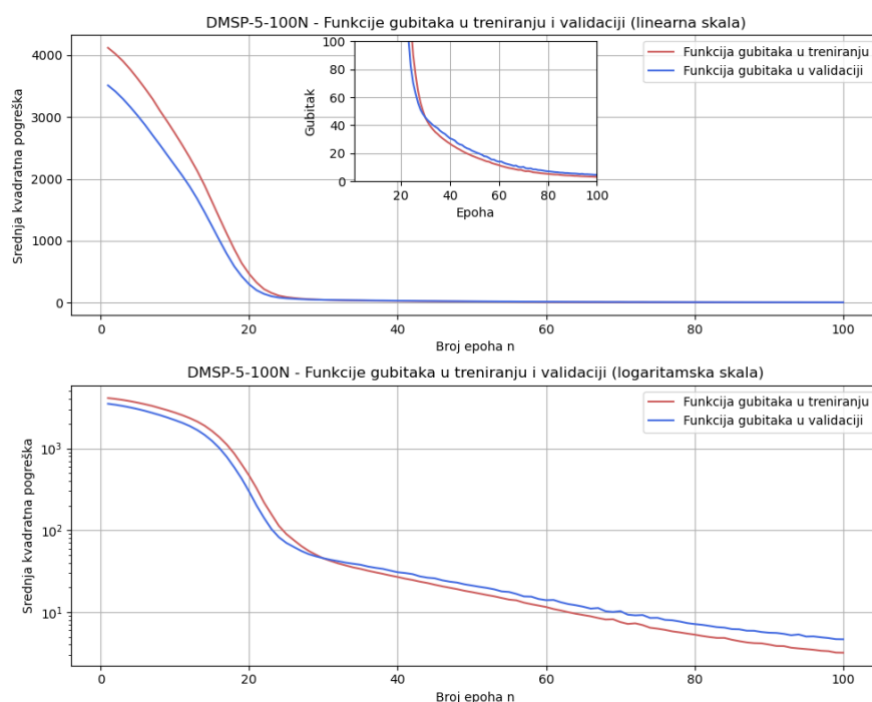
Sloj mreže	Broj neurona u sloju
Ulazni sloj	2
Skriveni sloj 1	64
Skriveni sloj 2	32
Izlazni sloj	1
Stopa učenja optimizatora	0.001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	100
Veličina serije	64

U Tablici 3.2 prikazani su numerički rezultati performansi modela za predikciju iznosa sile F za DMSP-5-100N model pneumatskog mišića. U testiranju je ostvaren je MAPE rezultat od 12.74%, RMSE rezultat od 1.84N te MSE 3.44.

Tablica 3.2. Numerički rezultati performansi modela za predikciju sile F za DMSP-5-100N model mišića


MAE		MSE		RMSE		MAPE	
Train	Test	Train	Test	Train	Test	Train	Test
1.318	1.327	3.583	3.438	1.893	1.854	12.270	12.737

Slika 3.1 daje uvid kako se funkcija gubitaka u treniranju i validaciji mijenja s brojem epoha. Ovakav prikaz je vrlo čest kod razmatranja performansi modela umjetne inteligencije. Razlog tomu je taj što promatranjem ponašanja funkcije gubitaka u treniranju, zajedno s funkcijom gubitaka u validaciji, može jednostavno zaključiti ako je model spreman za nove, neviđene podatke. Ukoliko se ova dva grafa počnu odmicati jedan od drugoga kroz epohe, tada je došlo do prenaučavanja modela, odnosno model je previše dobro naučio podatke za treniranje te neće biti u mogućnosti dobro raditi na novim podacima. Budući da je inicijalna pogreška prilikom treniranja visoka, graf je ujedno prikazan i na način da je os apscisa, zajedno s dekadskim mjerilom, prikazana i u logaritamskom mjerilu.




Slika 3.1. Funkcije gubitaka u treniranju i validaciji za model predikcije sile F za DMSP-5-100N model mišića

Slika 3.2 predstavlja devijaciju predviđenih vrijednosti modela od stvarnih vrijednosti. Crvena crta predstavlja liniju stvarnih vrijednosti iz testnog skupa, dok plavi kružići predstavljaju vrijednosti predviđene od strane modela. Radi preglednosti, zajedno s punom skalom, prikazana su i dva manja grafa s prvom i drugom polovicom pune skale.



Slika 3.2. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije sile F za DMSP-5-100N model mišića

Slikom 3.3 prikazana je distribucija apsolutnih pogrešaka predikcija modela. Poželjno je da je veća koncentracija pogrešaka manjeg iznosa, odnosno na skroz lijevoj strani grafa. Tako se može vidjeti i na prikazanom grafu kako je velika većina iznosa pogrešaka modela ispod $2N$, nekoliko desetaka pogrešaka u rasponima od $2N$ do $5.5N$ te samo nekoliko pogrešaka veći od $6N$.



Slika 3.3. Distribucija iznosa apsolutnih pogrešaka za model predikcije sile F za DMSP-5-100N model mišića

Prikazanim numeričkim podacima i vizualizacijskim pokazateljima, može se zaključiti kako model za predikciju iznosa sile za DMSP-5-100N tip pneumatskog mišića radi vrlo dobro te da nema većih pogrešaka u predikcijama.

3.1.2. Model za predviđanje iznosa kontrakcije nominalne duljine h

Arhitektura modela neuronske mreže se sastoji od tri sloja: ulaznog sloja s 2 neurona, jednog skrivenog sloja sa 100 neurona te izlaznog sloja s jednim neuronom. Model je treniran kroz 100 epoha sa stopom učenja optimizatora od 0.001, veličinom serije od 64 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Arhitektura modela prikazana je Tablicom 3.4.

Tablica 3.3. Arhitektura modela za predikciju kontrakcije h za DMSP-5-100N model mišića

Sloj mreže	Broj neurona u sloju
Ulazni sloj	2
Skriveni sloj 1	100
Izlazni sloj	1
Stopa učenja optimizatora	0.001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	100
Veličina serije	64


Numerički rezultati modela dani su Tablicom 3.5. Za razliku od modela za predikciju iznosa sile, modeli za predikciju iznosa kontrakcije nominalne duljine u svojim numeričkim pokazateljima performansi modela neće sadržavati Srednju apsolutnu postotnu pogrešku (MAPE) kao metriku. Razlog tomu je u samoj prirodi MAPE metrike. Ona može biti nepouzdana kod malih vrijednosti jer se prilikom izračuna dijeli sa stvarnom vrijednošću. Kad je ta stvarna vrijednost vrlo mala, i mala razlika između stvarne i predviđene vrijednosti može znatno uzrokovati vrlo veliku postotnu pogrešku. To može dovesti do izobličenja rezultata i prikazati performanse modela kao lošije nego što zaista jesu. Iz tog razloga će se za ovaj, ali i za sve ostale modele namijenjene predikciji iznosa kontrakcije nominalne duljine i tlaka za numeričke metrike koristiti samo MAE, MSE i RMSE.

Ostvaren iznos MSE-a nad testnim skupom je 1.355 te 1.164% za vrijednost RMSE-a.

Tablica 3.4. Numerički rezultati performansi modela za predikciju kontrakcije h za DMSP-5-100N


MAE		MSE		RMSE	
Train	Test	Train	Test	Train	Test
0.848	0.906	1.169	1.355	1.081	1.164

Slikom 3.4. prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Postignut je kontinuirani zajednički pad funkcija, bez odstupanja jedne funkcije od druge.




Slika 3.4. Funkcije gubitaka u treniranju i validaciji za model predikcije kontrakcije h za DMSP-5-100N model mišića

Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.5. Izuzet u pojedinim dijelovima skale, predikcije prate stvarne vrijednosti relativno točno s manjim oscilacijama.



Slika 3.5. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije kontrakcije h za DMSP-5-100N model mišića

Slikom 3.6 prikazana je distribucija apsolutnih pogrešaka u predikcijama modela. Većina iznosa pogrešaka smještena je na početku grafa što ukazuje na manje pogreške, s blagim porastom grešaka u rasponu od 2 do 2.5% iznosa kontrakcije mišića.



Slika 3.6. Distribucija iznosa apsolutnih pogrešaka za model predikcije kontrakcije h za DMSP-5-100N model mišića

Može se zaključiti kako realizirani model za predikciju iznosa kontrakcije nominalne duljine za DMSP-5-100N tip mišića daje vrlo dobre rezultate s manjim pogreškama.

3.1.3. Model za predviđanje iznosa tlaka p

Arhitektura modela neuronske mreže se sastoji od tri sloja: ulaznog sloja s 2 neurona, jednog skrivenog sloja sa 64 neurona te izlaznog sloja s jednim neuronom. Model je treniran kroz 50 epoha sa stopom učenja optimizatora od 0.001, veličinom serije 16 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Arhitektura modela prikazana je Tablicom 3.7.

Tablica 3.5. Arhitektura modela za predikciju tlaka p za DMSP-5-100N model mišića


Sloj mreže	Broj neurona u sloju
Ulazni sloj	2
Skriveni sloj 1	64
Izlazni sloj	1
Stopa učenja optimizatora	0.001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	50
Veličina serije	16

Numerički rezultati ostvareni modelom dani su Tablicom 3.8. Ostvaren iznos MSE-a nad testnim skupom je 0.035 te 0.187bara za vrijednost RMSE-a.

Tablica 3.6. Numerički rezultati performansi modela za predikciju tlaka p za DMSP-5-100N


MAE		MSE		RMSE	
Train	Test	Train	Test	Train	Test
0.144	0.149	0.033	0.035	0.183	0.187

Slikom 3.7. prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Postignut je kontinuirani zajednički pad funkcija, bez odstupanja jedne funkcije od druge.




Slika 3.7. Funkcije gubitaka u treniranju i validaciji za model predikcije tlaka p za DMSP-5-100N model mišića

Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.8. Predikcije prate stvarne vrijednosti relativno točno s manjim oscilacijama.



Slika 3.8. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije tlaka p za DMSP-5-100N model mišića

Slikom 3.9 prikazana je distribucija apsolutnih pogrešaka u predikcijama modela. Maksimalna pogreška modela je u iznosi od oko 0.5 bara dok je ostatak pogrešaka smješten u rasponu od 0 do 0.4 bara.



Slika 3.9. Distribucija iznosa apsolutnih pogrešaka za model predikcije tlaka p za DMSP-5-100N model mišića

Realizirani model za predikciju iznosa tlaka daje gotovo odlične rezultate s minimalnim pogreškama.

3.2. DMSP 10-100N tip pneumatskog mišića

DMSP-10-100N je slijedeći u nizu razmatranih FESTO pneumatskih mišića. Karakteriziraju ga nešto veće vrijednosti iznosa sile nego kod DMSP-5-100N modela. Za pneumatski mišić realizirana su tri regresijska modela: predikcija iznosa sile, kontrakcije nominalne duljine te iznosa tlaka. U nastavku su prikazani rezultati dobivenih modela.

3.2.1. Model za predviđanje iznosa dopuštene sile F

Arhitektura modela neuronske mreže se sastoji od šest slojeva: ulaznog sloja s 2 neurona, četiri skrivena sloja sa po 128, 64, 32 i 16 neurona slijedno te izlaznog sloja s jednim neuronom. Model je treniran kroz 200 epoha sa stopom učenja optimizatora od 0.001, veličinom serije 64 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Arhitektura modela prikazana je Tablicom 3.10.

Tablica 3.7. Arhitektura modela za predikciju sile F za DMSP-10-100N model mišića


Sloj mreže	Broj neurona u sloju
Ulazni sloj	2
Skriveni sloj 1	128
Skriveni sloj 2	64
Skriveni sloj 3	32
Skriveni sloj 4	16
Izlazni sloj	1
Stopa učenja optimizatora	0.001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	200
Veličina serije	64

Numerički rezultati performansi modela dani su Tablicom 3.11. Model je u treniranju ostvario iznos MAPE-a od 3.52 dok je na testnom skupu ostvario nešto lošiji rezultat od 4.302.

Tablica 3.8. Numerički rezultati performansi modela za predikciju sile F za DMSP-10-100N model mišića


MAE		MSE		RMSE		MAPE	
Train	Test	Train	Test	Train	Test	Train	Test
1.838	1.858	6.930	7.620	2.633	2.760	3.515	4.302

Slikom 3.10 prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Postignut je kontinuirani zajednički pad funkcija, bez odstupanja jedne funkcije od druge. Zbog inicijalno velike pogreške tijekom treniranja modela, logaritamska skala daje bolji uvid u promjenu funkcijama gubitaka kroz epohe.




Slika 3.10. Funkcije gubitaka u treniranju i validaciji za model predikcije sile F za DMSP-10-100N model mišića

Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.11. Predikcije modela prate stvarne vrijednosti relativno točno s manjim oscilacijama.



Slika 3.11. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije sile F za DMSP-10-100N model mišića

Iz grafa distribucija apsolutnih pogrešaka na Slici 3.12 vidljivo je kako je većina iznosa pogrešaka u rasponu od 0 do $6N$ što ukazuje na dobre rezultate realiziranog modela.



Slika 3.12. Distribucija iznosa apsolutnih pogrešaka za model predikcije sile F za DMSP-10-100N model mišića

3.2.2. Model za predviđanje iznosa kontrakcije nominalne duljine h

Arhitektura modela neuronske mreže se sastoji od tri sloja: ulaznog sloja s 2 neurona, jednog skrivenog sloja sa 128 neurona te izlaznog sloja s jednim neuronom. Model je treniran kroz 100 epoha sa stopom učenja optimizatora od 0.001, veličinom serije 64 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Arhitektura modela prikazana je Tablicom 3.13.

Tablica 3.9. Arhitektura modela za predikciju kontrakcije h za DMSP-10-100N model mišića


Sloj mreže	Broj neurona u sloju
Ulazni sloj	2
Skriveni sloj 1	128
Izlazni sloj	1
Stopa učenja optimizatora	0.001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	100
Veličina serije	64

Numerički rezultati ostvareni modelom dani su Tablicom 3.14. Ostvaren iznos MSE-a nad testnim skupom je 0.868 te 0.931% za vrijednost RMSE-a.

Tablica 3.10. Numerički rezultati performansi modela za predikciju kontrakcije h za DMSP-10-100N model mišića


MAE		MSE		RMSE	
Train	Test	Train	Test	Train	Test
0.669	0.704	0.787	0.868	0.887	0.931

Slikom 3.13. prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Postignut je kontinuirani zajednički pad funkcija, bez odstupanja jedne funkcije od druge.




Slika 3.13. Funkcije gubitaka u treniranju i validaciji za model predikcije kontrakcije h za DMSP-10-100N model mišića

Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.14. Izuzet u pojedinim dijelovima skale, predikcije prate stvarne vrijednosti relativno točno s manjim oscilacijama.



Slika 3.14. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije kontrakcije h za DMSP-10-100N model mišića

Slikom 3.15 prikazana je distribucija apsolutnih pogrešaka u predikcijama modela. Većina iznosa pogrešaka smještena je na početku grafa što ukazuje na manje pogreške, s blagim porastom grešaka u rasponu od 1 do 2% iznosa kontrakcije mišića. Realizirani model daje dobre rezultate s većinom pogrešaka u rasponu od 0 do 1% iznosa kontrakcije nominalne duljine.



Slika 3.15. Distribucija iznosa apsolutnih pogrešaka za model predikcije kontrakcije h za DMSP-10-100N model mišića

3.2.3. Model za predviđanje iznosa tlaka p

Arhitektura modela neuronske mreže se sastoji od tri sloja: ulaznog sloja s 2 neurona, jednog skrivenog sloja sa 64 neurona te izlaznog sloja s jednim neuronom. Model je treniran kroz 50 epoha sa stopom učenja optimizatora od 0.001, veličinom serije 16 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Arhitektura modela prikazana je Tablicom 3.16.

Tablica 3.11. Arhitektura modela za predikciju tlaka p za DMSP-10-100N model mišića


Sloj mreže	Broj neurona u sloju
Ulazni sloj	2
Skriveni sloj 1	64
Izlazni sloj	1
Stopa učenja optimizatora	0.001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	50
Veličina serije	16

Metrički rezultati u treniranju i testiranju su vrlo slični te su prikazani u Tablici 3.17. MSE vrijednost nad testnim skupom podataka iznosi 0.115 dok RMSE iznosi 0.339bara.

Tablica 3.12. Numerički rezultati performansi modela za predikciju tlaka p za DMSP-10-100N model mišića


MAE		MSE		RMSE	
Train	Test	Train	Test	Train	Test
0.256	0.268	0.107	0.115	0.327	0.339

Slikom 3.16. prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Pri kraju dolazi do pojave nekoliko skokova kod krivulja. Međutim, postignut je kontinuirani zajednički pad funkcija, bez značajnog odstupanja jedne funkcije od druge.



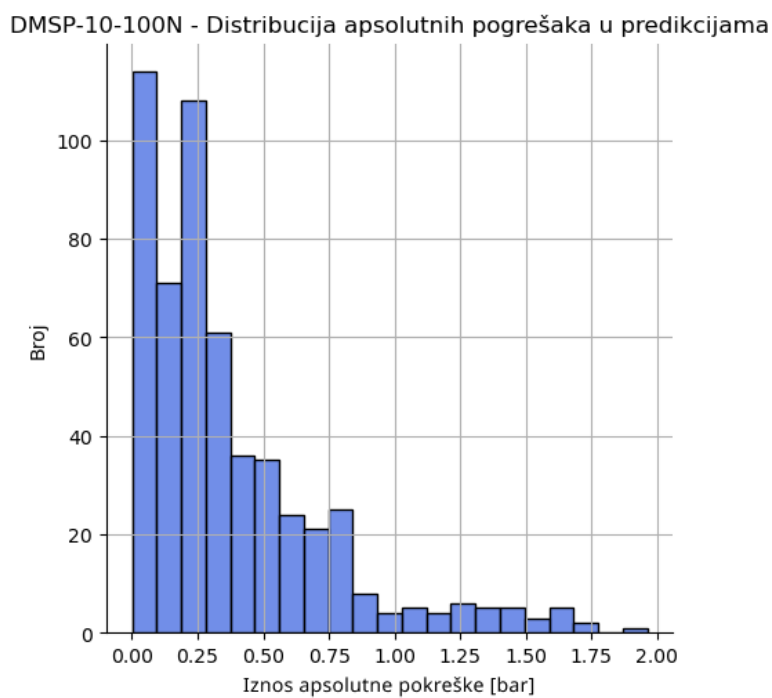
Slika 3.16. Funkcije gubitaka u treniranju i validaciji za model predikcije tlaka p za DMSP-10-100N model mišića

Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.17. Maksimalno zabilježeno odstupanje je u iznosu nešto manjem od 2bara.



Slika 3.17. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije tlaka p za DMSP-10-100N model mišića

Slikom 3.18 prikazana je distribucija apsolutnih pogrešaka u predikcijama modela. Iznosi apsolutnih pogrešaka u predikcijama modela većinski se nalaze u rasponu od 0 do 0.80bara čineći model vrlo dobrim.



Slika 3.18. Distribucija iznosa apsolutnih pogrešaka za model predikcije tlaka p za DMSP-10-100N model mišića

3.3. DMSP 20-200N tip pneumatskog mišića

DMSP-20-200N je treći u nizu razmatranih FESTO pneumatskih mišića. Za pneumatski mišić realizirana su tri regresijska modela: predikcija iznosa sile, kontrakcije nominalne duljine te iznosa tlaka. U nastavku su prikazani rezultati dobivenih modela.

3.3.1. Model za predviđanje iznosa dopuštene sile F

Arhitektura modela neuronske mreže se sastoji od šest slojeva: ulaznog sloja s 2 neurona, četiri skrivena sloja sa po 128, 128, 32 i 16 neurona slijedno te izlaznog sloja s jednim neuronom. Model je treniran kroz 300 epoha sa stopom učenja optimizatora od 0.001, veličinom serije 64 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Arhitektura modela prikazana je Tablicom 3.19.

Tablica 3.13. Arhitektura modela za predikciju sile F za DMSP-20-200N model mišića


Sloj mreže	Broj neurona u sloju
Ulazni sloj	2
Skriveni sloj 1	128
Skriveni sloj 2	128
Skriveni sloj 3	32
Skriveni sloj 4	16
Izlazni sloj	1
Stopa učenja optimizatora	0.001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	300
Veličina serije	64

Numerički rezultati performansi modela dani su Tablicom 3.20. Nad testnim skupom podataka ostvaren je MAPE rezultat od 3.791%, RMSE rezultat od 7.719N, te MSE rezultat do 59.577.

Tablica 3.14. Numerički rezultati performansi modela za predikciju sile F za DMSP-20-200N model mišića


MAE		MSE		RMSE		MAPE	
Train	Test	Train	Test	Train	Test	Train	Test
4.830	5.380	46.983	59.577	6.854	7.719	2.873	3.791

Slikom 3.19. prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Postignut je kontinuirani zajednički pad funkcija, bez odstupanja jedne funkcije od druge.



Slika 3.19. Funkcije gubitaka u treniranju i validaciji za model predikcije sile F za DMSP-20-200N model mišića


Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.20. Izuzet u pojedinim dijelovima skale, predikcije prate stvarne vrijednosti relativno točno s manjim oscilacijama.



Slika 3.20. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije sile F za DMSP-20-200N model mišića

Slikom 3.21 prikazana je distribucija apsolutnih pogrešaka u predikcijama modela. Većina iznosa pogrešaka smještena je u rasponu od 0 do 8N što ukazuje na manje pogreške i dobru točnost modela.

DMSP-20-200N - Distribucija apsolutnih pogrešaka u predikcijama



Slika 3.21. Distribucija iznosa apsolutnih pogrešaka za model predikcije sile F za DMSP-20-200N model mišića

3.3.2. Model za predviđanje iznosa kontrakcije nominalne duljine h

Arhitektura modela neuronske mreže se sastoji od tri sloja: ulaznog sloja s 2 neurona, jednog skrivenog sloja sa 128 neurona te izlaznog sloja s jednim neuronom. Model je treniran kroz 150 epoha sa stopom učenja optimizatora od 0.001, veličinom serije 64 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Arhitektura modela prikazana je Tablicom 3.22.

Tablica 3.15. Arhitektura modela za predikciju kontrakcije h za DMSP-20-200N model mišića

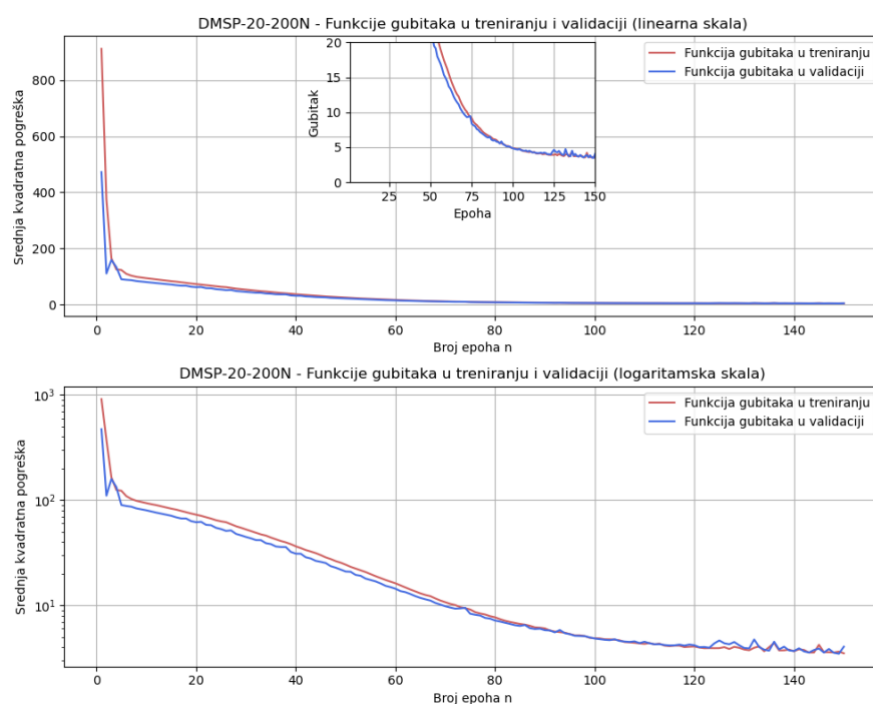
Sloj mreže	Broj neurona u sloju
Ulazni sloj	2
Skriveni sloj 1	128
Izlazni sloj	1
Stopa učenja optimizatora	0.001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	150
Veličina serije	64

Metrički rezultati u treniranju i testiranju su prikazani u Tablici 3.23. MSE vrijednost nad testnim skupom podataka iznosi 4.106 dok RMSE iznosi 2.026 *bara*.

Tablica 3.16. Numerički rezultati performansi modela za predikciju kontrakcije h za DMSP-20-200N model mišića


MAE		MSE		RMSE	
Train	Test	Train	Test	Train	Test
1.719	1.748	3.977	4.106	1.994	2.026

Slikom 3.22. prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Postignut je kontinuirani zajednički pad funkcija, bez odstupanja jedne funkcije od druge.




Slika 3.22. Funkcije gubitaka u treniranju i validaciji za model predikcije kontrakcije h za DMSP-20-200N model mišića

Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.23. U modelu su prisutna nešto znatnija odstupanja predikcija modela od stvarnih vrijednosti



Slika 3.23. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije kontrakcije h za DMSP-20-200N model mišića

Slikom 3.24 prikazana je distribucija apsolutnih pogrešaka u predikcijama modela. Najviše pogrešaka prisutno je u rasponima od 0 do 3% iznosa kontrakcije nominalne duljine mišića.



Slika 3.24. Distribucija iznosa apsolutnih pogrešaka za model predikcije kontrakcije h za DMSP-20-200N model mišića

3.3.3. Model za predviđanje iznosa tlaka p

Arhitektura modela neuronske mreže se sastoji od tri sloja: ulaznog sloja s 2 neurona, jednog skrivenog sloja sa 64 neurona te izlaznog sloja s jednim neuronom. Model je treniran kroz 100 epoha sa stopom učenja optimizatora od 0.001, veličinom serije 16 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Arhitektura modela prikazana je Tablicom 3.25.

Tablica 3.17. Arhitektura modela za predikciju tlaka p za DMSP-20-200N model mišića

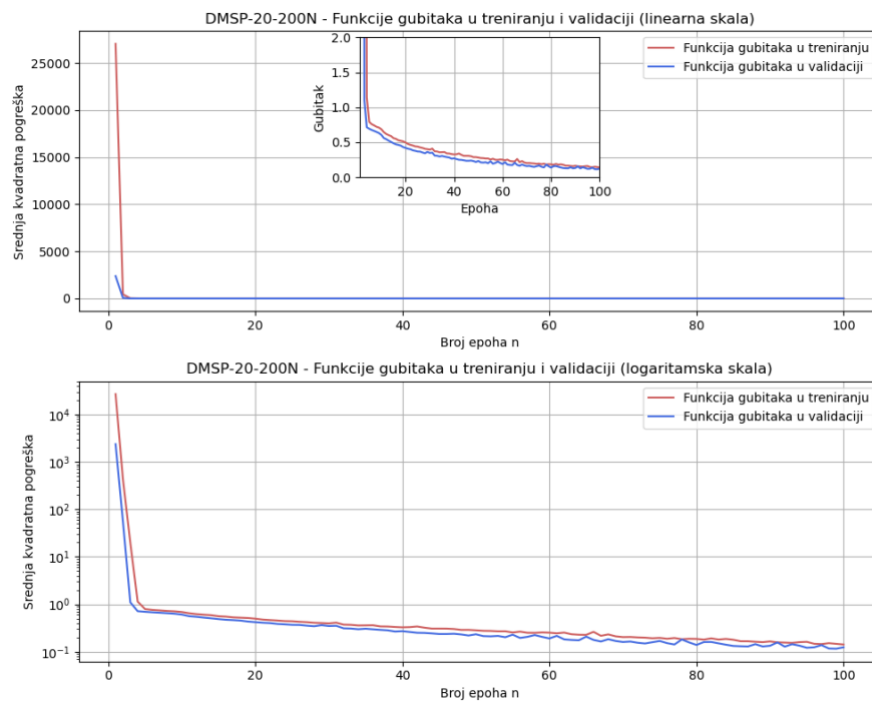
Sloj mreže	Broj neurona u sloju
Ulazni sloj	2
Skriveni sloj 1	64
Izlazni sloj	1
Stopa učenja optimizatora	0.001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	100
Veličina serije	16

U Tablici 3.26. prikazani su rezultati dobivenih numeričkih pokazatelja performansi modela. Ostvaren je MSE rezultat od 0.212 te RMSE rezultat od 0.460bara.

Tablica 3.18. Numerički rezultati performansi modela za predikciju tlaka p za DMSP-20-200N model mišića


MAE		MSE		RMSE	
Train	Test	Train	Test	Train	Test
0.266	0.317	0.137	0.212	0.370	0.460

Slikom 3.25. prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Postignut je kontinuirani zajednički pad funkcija, bez odstupanja jedne funkcije od druge.



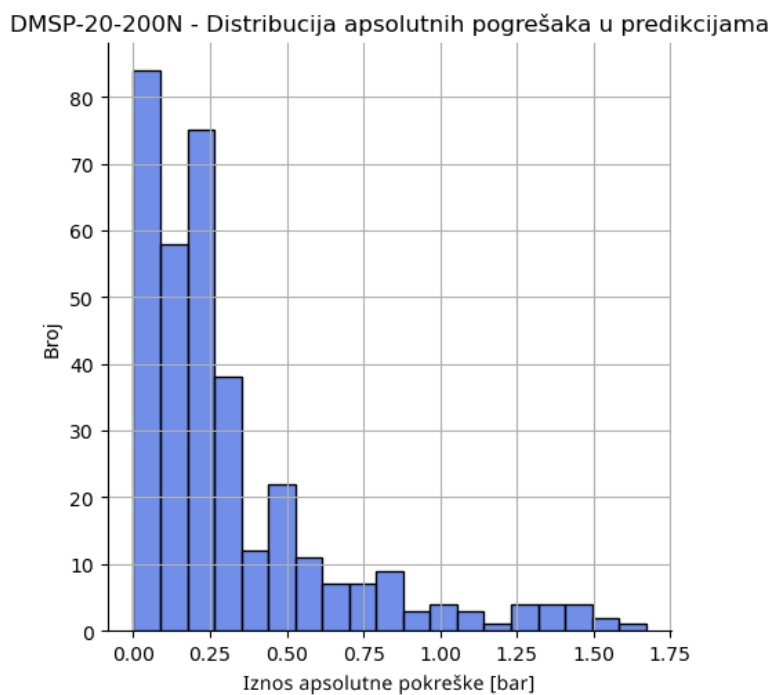
Slika 3.25. Funkcije gubitaka u treniranju i validaciji za model predikcije tlaka p za DMSP-20-200N model mišića

Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.26. najveće zabilježeno odstupanje je iznosa nešto manje od 1.75 bara.



Slika 3.26. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije tlaka p za DMSP-20-200N model mišića

Slikom 3.27 prikazana je distribucija apsolutnih pogrešaka u predikcijama modela. Većina pogrešaka prisutnih u predikcijama modela nalazi se u rasponu iznosa od 0 do 0.5 bara.



Slika 3.27. Distribucija iznosa apsolutnih pogrešaka za model predikcije tlaka p za DMSP-20-200N model mišića

3.4. DMSP 40-400N tip pneumatskog mišića

Posljednji u nizu razmatranih FESTO pneumatskih mišića je i DMSP-40-400N. On predstavlja najveći od svih razmatranih modela te ga time karakteriziraju i najveći iznosi sile. Za pneumatski mišić realizirana su tri regresijska modela: predikcija iznosa sile, kontrakcije nominalne duljine te iznosa tlaka. U nastavku su prikazani rezultati dobivenih modela.

3.4.1. Model za predviđanje iznosa dopuštene sile F

Arhitektura modela neuronske mreže se sastoji od šest slojeva: ulaznog sloja s 2 neurona, četiri skrivena sloja sa po 128, 128, 128 i 16 neurona redom te izlaznog sloja s jednim neuronom. Model je treniran kroz 300 epoha sa stopom učenja optimizatora od 0.001, veličinom serije 64 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Arhitektura modela prikazana je Tablicom 3.28.

Tablica 3.19. Arhitektura modela za predikciju sile F za DMSP-40-400N model mišića


Sloj mreže	Broj neurona u sloju
Ulazni sloj	2
Skriveni sloj 1	128
Skriveni sloj 2	128
Skriveni sloj 3	128
Skriveni sloj 4	16
Izlazni sloj	1
Stopa učenja optimizatora	0.001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	300
Veličina serije	64

Numerički rezultati performansi modela dani su Tablicom 3.29. Nad testnim skupom podataka ostvaren je MAPE rezultat od 1.221%, RMSE rezultat od 15.552N, te MSE rezultat do 241.875.

Tablica 3.20. Numerički rezultati performansi modela za predikciju sile F za DMSP-40-400N model mišića


MAE		MSE		RMSE		MAPE	
Train	Test	Train	Test	Train	Test	Train	Test
10.354	11.268	197.151	241.875	14.041	15.552	1.123	1.221

Slikom 3.28. prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Postignut je kontinuirani zajednički pad funkcija, bez odstupanja jedne funkcije od druge.




Slika 3.28. Funkcije gubitaka u treniranju i validaciji za model predikcije sile F za DMSP-40-400N model mišića

Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.29. Izuzet u pojedinim dijelovima skale, predikcije prate stvarne vrijednosti relativno točno s manjim oscilacijama.



Slika 3.29. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije sile F za DMSP-40-400N model mišića

Na Slici 3.30 je vidljivo kako se većina apsolutnih pogrešaka u predikcijama modela nalazi u rasponu od 0 do 20N sa nekoliko izuzetaka s većim odstupanjima.



Slika 3.30. Distribucija iznosa apsolutnih pogrešaka za model predikcije sile F za DMSP-40-400N model mišića

3.4.2. Model za predviđanje iznosa kontrakcije nominalne duljine h

Arhitektura modela neuronske mreže se sastoji od tri sloja: ulaznog sloja s 2 neurona, jednog skrivenog sloja sa 256 neurona te izlaznog sloja s jednim neuronom. Model je treniran kroz 100 epoha sa stopom učenja optimizatora od 0.001, veličinom serije 64 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Arhitektura modela prikazana je Tablicom 3.31.

Tablica 3.21. Arhitektura modela za predikciju kontrakcije h za DMSP-40-400N model mišića


Sloj mreže	Broj neurona u sloju
Ulazni sloj	2
Skriveni sloj 1	256
Izlazni sloj	1
Stopa učenja optimizatora	0.001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	100
Veličina serije	64

U Tablici 3.32. prikazani su rezultati dobivenih numeričkih pokazatelja performansi modela. Ostvaren je MSE rezultat od 14.381 te RMSE rezultat od 3.792%.

Tablica 3.22. Numerički rezultati performansi modela za predikciju kontrakcije h za DMSP-40-400N model mišića


MAE		MSE		RMSE	
Train	Test	Train	Test	Train	Test
3.142	3.049	14.481	14.381	3.805	3.792

Slikom 3.31. prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Vidljivo je kako je prisutno malo odstupanje u funkcijama tijekom zajedničkog pada. Ovo može sugerirati na nešto lošije performanse modela.




Slika 3.31. Funkcije gubitaka u treniranju i validaciji za model predikcije kontrakcije h za DMSP-40-400N model mišića

Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.32. Kako je bilo za očekivati s prethodnog grafa funkcija u treniranju i testiranju, model pokazuje nešto lošije rezultate s na određenim mjestima velikim pogreškama u predikcijama.



Slika 3.32. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije kontrakcije h za DMSP-40-400N model mišića

Slikom 3.33 prikazana je distribucija apsolutnih pogrešaka u predikcijama modela. Većina iznosa pogrešaka smještena je u rasponu od 0 do 5%, međutim izdvaja se količina pogrešaka od oko 3.5% sa više od 70 ponavljanja.



Slika 3.33. Distribucija iznosa apsolutnih pogrešaka za model predikcije kontrakcije h za DMSP-40-400N model mišića

3.4.3. Model za predviđanje iznosa tlaka p

Arhitektura modela neuronske mreže se sastoji od tri sloja: ulaznog sloja s 2 neurona, jednog skrivenog sloja sa 128 neurona te izlaznog sloja s jednim neuronom. Model je treniran kroz 50 epoha sa stopom učenja optimizatora od 0.001, veličinom serije 16 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Arhitektura modela prikazana je Tablicom 3.34.

Tablica 3.23. Arhitektura modela za predikciju tlaka p za DMSP-40-400N model mišića


Sloj mreže	Broj neurona u sloju
Ulazni sloj	2
Skriveni sloj 1	128
Izlazni sloj	1
Stopa učenja optimizatora	0.001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	50
Veličina serije	16

U Tablici 3.35. prikazani su rezultati dobivenih numeričkih pokazatelja performansi modela. Ostvaren je MSE rezultat od 0.170 te RMSE rezultat od 0.413bara.

Tablica 3.24. Numerički rezultati performansi modela za predikciju tlaka p za DMSP-40-400N model mišića

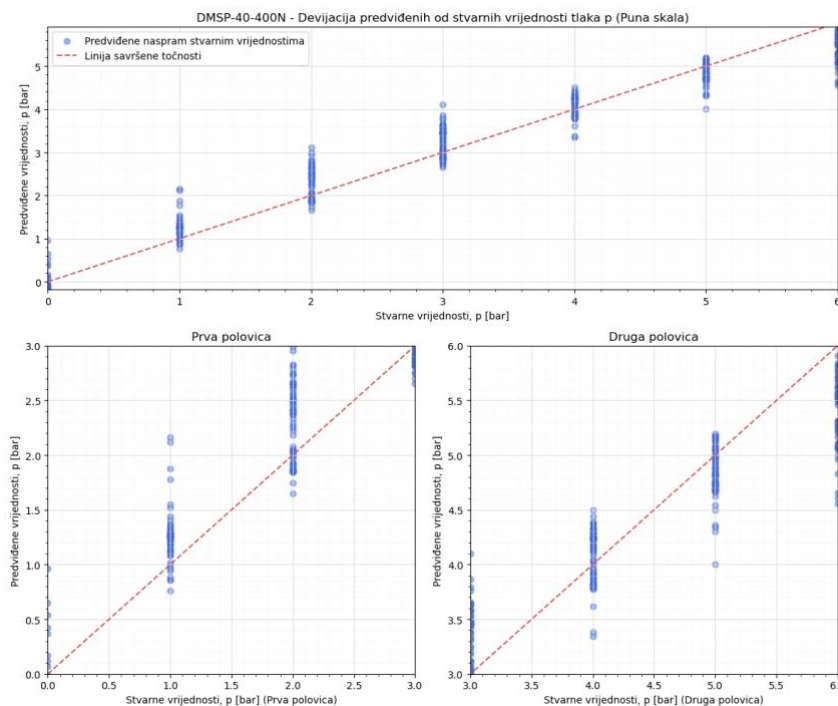
MAE		MSE		RMSE	
Train	Test	Train	Test	Train	Test
0.338	0.324	0.176	0.170	0.420	0.413

Slikom 3.34. prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Postignut je kontinuirani zajednički pad funkcija, bez odstupanja jedne funkcije od druge, međutim uz pojavu određenih skokova u funkcijama.




Slika 3.34. Funkcije gubitaka u treniranju i validaciji za model predikcije tlaka p za DMSP-40-400N model mišića

Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.35. najveće zabilježeno odstupanje je iznosa nešto manje od 1.2bara.



Slika 3.35. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije tlaka p za DMSP-40-400N model mišića

Slikom 3.36 prikazana je distribucija apsolutnih pogrešaka u predikcijama modela. Većina iznosa pogrešaka smještena je u rasponu od 0 do 0.4bara.



Slika 3.36. Distribucija iznosa apsolutnih pogrešaka za model predikcije tlaka p za DMSP-40-400N model mišića

3.5. Skupni podaci sa svim tipovima pneumatskog mišića

Dosad su bili predstavljeni rezultati modela za pojedinačne razmatrane tipove pneumatskih mišića. Posljednja tri modela razmatrat će kombinirane podatke svih tipova pneumatskih mišića zajedno. Time su dobiveni generalni modeli. Za skupni set podataka realizirana su tri regresijska modela: predikcija iznosa sile, kontrakcije nominalne duljine te iznosa tlaka. U nastavku su prikazani rezultati dobivenih modela.

3.5.1. Model za predviđanje iznosa dopuštene sile F

Arhitektura modela neuronske mreže se sastoji od sedam slojeva: ulaznog sloja s 3 neurona, četiri skrivena sloja svaki sa po 128 neurona te izlaznog sloja s jednim neuronom. Model je treniran kroz 300 epoha sa stopom učenja optimizatora od 0.0001, veličinom serije 32 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Ovaj model predstavlja do sada najkompleksniji model s najviše slojeva i neurona te ujedno i s jednim ulaznim parametrom više koji predstavlja tip mišića. Arhitektura modela prikazana je Tablicom 3.37.

Tablica 3.25. Arhitektura modela za predikciju sile F za skupni set podataka


Sloj mreže	Broj neurona u sloju
Ulazni sloj	3
Skriveni sloj 1	128
Skriveni sloj 2	128
Skriveni sloj 3	128
Skriveni sloj 4	128
Skriveni sloj 5	128
Izlazni sloj	1
Stopa učenja optimizatora	0.0001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	200
Veličina serije	32

Numerički rezultati performansi modela dani su Tablicom 3.38. Nad testnim skupom podataka ostvaren je MAPE rezultat od 6.513%, RMSE rezultat od 11.504*N*, te MSE rezultat od 132.336.

Tablica 3.26. Numerički rezultati performansi modela za predikciju sile F za skupni set podataka


MAE		MSE		RMSE		MAPE	
Train	Test	Train	Test	Train	Test	Train	Test
6.795	7.509	97.197	132.336	9.859	11.504	5.941	6.513

Slikom 3.37. prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Funkcije gubitaka u treniranju i validaciji su sadržavale dosta skokova u drugoj polovici faze treniranja. Smanjenju skokova doprinijelo je smanjivanje stope učenja optimizatora sa 0.001 na 0.0001.




Slika 3.37. Funkcije gubitaka u treniranju i validaciji za model predikcije sile F za skupni set podataka

Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.38. Izuzet u pojedinim dijelovima skale, predikcije prate stvarne vrijednosti relativno točno s manjim oscilacijama.



Slika 3.38. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije sile F za skupni set podataka

Slikom 3.39 prikazana je distribucija apsolutnih pogrešaka u predikcijama modela. Greške u predikcijama modela većinski se nalaze u rasponu iznosa sile od 0 do $20N$ s pojedinim ekstremima koji dostižu čak i $80N$.



Slika 3.39. Distribucija iznosa apsolutnih pogrešaka za model predikcije sile F za skupni set podataka

3.5.2. Model za predviđanje iznosa kontrakcije nominalne duljine h

Arhitektura modela neuronske mreže se sastoji od četiri sloja: ulaznog sloja s 3 neurona, dva skrivena sloja sa 128 i 64 neurona redom, te izlaznog sloja s jednim neuronom. Model je treniran kroz 200 epoha sa stopom učenja optimizatora od 0.0001, veličinom serije 32 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Arhitektura modela prikazana je Tablicom 3.40.

Tablica 3.27. Arhitektura modela za predikciju kontrakcije h za skupni set podataka


Sloj mreže	Broj neurona u sloju
Ulazni sloj	3
Skriveni sloj 1	256
Skriveni sloj 2	64
Izlazni sloj	1
Stopa učenja optimizatora	0.0001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	200
Veličina serije	32

U Tablici 3.41. prikazani su rezultati dobivenih numeričkih pokazatelja performansi modela. Ostvaren je MSE rezultat od 6.015 te RMSE rezultat od 2.453bara.

Tablica 3.28. Numerički rezultati performansi modela za predikciju kontrakcije h za skupni set podataka


MAE		MSE		RMSE	
Train	Test	Train	Test	Train	Test
1.794	1.819	5.755	6.015	2.399	2.453

Slikom 3.40. prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Iz grafa se može vidjeti kako postoje značajni skokovi i vrijednostima funkcijama kroz cijeli proces treniranja modela. Smanjivanje iznosa stope učenja optimizatora je u određenoj mjeri pomoglo s ovim problemom.




Slika 3.40. Funkcije gubitaka u treniranju i validaciji za model predikcije kontrakcije h za skupni set podataka

Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.41. Izuzet u pojedinim dijelovima skale, predikcije prate stvarne vrijednosti relativno točno s manjim oscilacijama.



Slika 3.41. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije kontrakcije h za skupni set podataka

Slikom 3.42 prikazana je distribucija apsolutnih pogrešaka u predikcijama modela. Većina iznosa pogrešaka smještena je na početku grafa što ukazuje na manje pogreške u predikcijama.



Slika 3.42. Distribucija iznosa apsolutnih pogrešaka za model predikcije kontrakcije h za skupni set podataka

3.5.3. Model za predviđanje iznosa tlaka p

Arhitektura modela neuronske mreže se sastoji od tri sloja: ulaznog sloja s 3 neurona, jednog skrivenog sloja sa 256 neurona te izlaznog sloja s jednim neuronom. Model je treniran kroz 100 epoha sa stopom učenja optimizatora od 0.0001, veličinom serije 16 te srednjom kvadratnom pogreškom kao funkcijom gubitaka. Arhitektura modela prikazana je Tablicom 3.43.

Tablica 3.29. Arhitektura modela za predikciju tlaka p za skupni set podataka

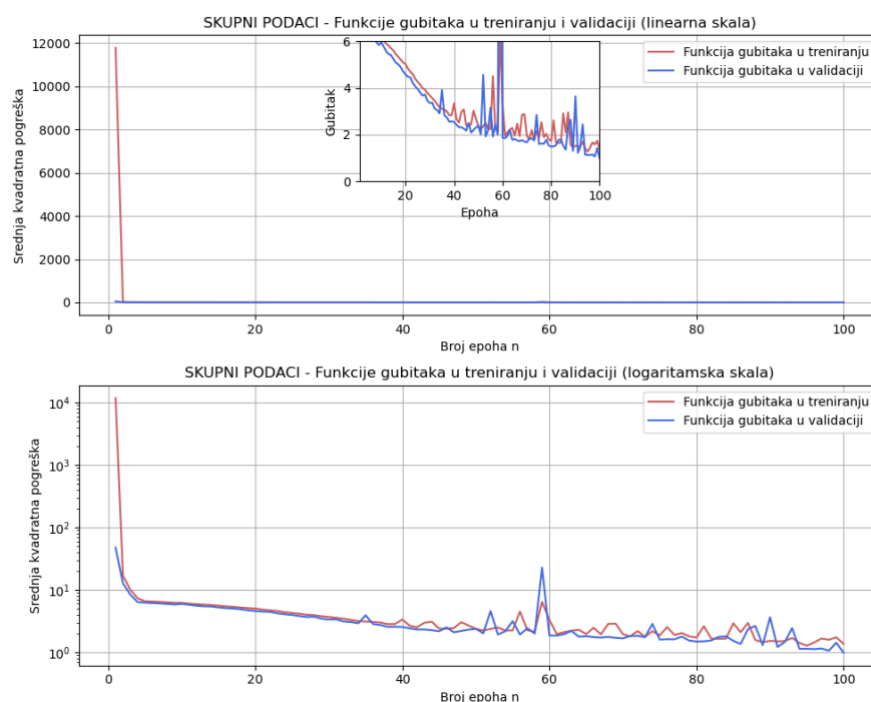
Sloj mreže	Broj neurona u sloju
Ulazni sloj	3
Skriveni sloj 1	256
Izlazni sloj	1
Stopa učenja optimizatora	0.0001
Aktivacijska funkcija	ReLU
Funkcija gubitaka	Srednja kvadratna pogreška
Broj epoha	100
Veličina serije	16

U Tablici 3.44. prikazani su rezultati dobivenih numeričkih pokazatelja performansi modela. Ostvaren je MSE rezultat od 0.997 te RMSE rezultat od 0.999bara.

Tablica 3.30. Numerički rezultati performansi modela za predikciju tlaka p za skupni set podataka


MAE		MSE		RMSE	
Train	Test	Train	Test	Train	Test
0.739	0.731	1.029	0.997	1.014	0.999

Slikom 3.43. prikazane su funkcije gubitaka u treniranju i validaciji na linearnoj i logaritamskoj skali. Postignut je kontinuirani zajednički pad funkcija, bez odstupanja jedne funkcije od druge. Također, kao i prije, prisutni su određeni skokovi u iznosima funkcijama gubitaka tijekom procesa treniranja i validacije.




Slika 3.43. Funkcije gubitaka u treniranju i validaciji za model predikcije tlaka p za skupni set podataka

Devijacije predviđenih vrijednosti modela od stvarnih vrijednosti prikazane su na Slici 3.44. Najveće zabilježeno odstupanje je iznosa nešto manje od 1.2bara.



Slika 3.44. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije tlaka p za skupni set podataka

Slikom 3.45 prikazana je distribucija apsolutnih pogrešaka u predikcijama modela. Većina iznosa pogrešaka smještena je u rasponu od 0 do 1bar.



Slika 3.45. Distribucija iznosa apsolutnih pogrešaka za model predikcije tlaka p za skupni set podataka

4. ZAKLJUČAK

Ovaj rad proveo je istraživanje na temu regresijskog modeliranja pneumatskih mišića korištenjem umjetnih neuronskih mreža, s posebnim fokusom na četiri različita tipa pneumatskih mišića. Cilj rada bio je adresirati izazove koje postavlja nelinearno i složeno ponašanje pneumatskih mišića primjenom modela višeslojnog perceptrona za predviđanje sile, tlaka i kontrakcije nominalne duljine kod različitih tipova pneumatskih mišića.

Podaci za treniranje modela prikupljeni su iz službenog tehničkog dokumenta proizvođača pneumatskog mišića. Nad prikupljenim podacima je potom provedena statistička analiza i obrada podataka, time dobivajući bolji uvid u ponašanje podataka unutar skupa te ih ujedno pripremajući za korištenje u treniranju modela. Predstavljena je i objašnjena metodologija neuronskih mreža zajedno s njezinim elementima s fokusom na višeslojni perceptron. Također, objašnjen je i postupak implementacije modela u Python programskom jeziku korištenjem TensorFlow knjižnice.

Realizirano je 15 pojedinačnih modela, ciljajući četiri različita tipa mišića (5-100N, 10-100N, 20-200N, 40-400N), uključujući tri modela koja ciljaju skup podataka sastavljen od sva četiri tipa mišića istovremeno. Predstavljene su rezultati performansi svakog od modela putem raznih numeričkih metričkih pokazatelja kao što su srednja kvadratna pogreška, srednja apsolutna postotna pogreška i dr. Isto tako, radi boljeg razumijevanja i predodžbe rezultata, prikazani su i razni vizualizacijski grafički pokazatelji performansi modela. Oni uključuju graf funkcija gubitaka u treniranju i validaciji, graf devijacija predviđenih vrijednosti od stvarnih vrijednosti modela te graf distribucija iznosa apsolutnih pogrešaka u predikcijama modela.

Razvijeni modeli pokazali su da je moguće postići određenu razinu točnosti regresije koristeći samo modele višeslojnog perceptrona. Nešto bolje performanse u usporedbi s ostalim modelima pokazao je model treniran na kombiniranom skupu podataka koji obuhvaća sve četiri vrste mišića. Ovo sugerira da korištenje raznolikog i većeg skupa podataka može poboljšati mogućnost generalizacije modela te povećati prediktivnu snagu neuronske mreže u ovom slučaju. Međutim, postoje određena mjesta za poboljšanja. Neka od njih mogu uključivati odabir drugih modela umjetne inteligencije, poboljšanje kvalitete skupa podataka uključivanjem obuhvatnijih eksperimentalnih uvjeta prikupljanja podataka i slično.

Sveukupno, ovaj rad daje osnovu za daljnje istraživanje primjene algoritama umjetne inteligencije u području modeliranja pneumatskih mišića. Istraživački napredci u ovom području pneumatskih mišića mogu uvelike doprinijeti razvoju unutar robotike i biomedicinskom području, gdje su točno i učinkovito modeliranje pneumatskih mišića ključni za razvoj naprednih sustava.

5. LITERATURA

- [1] Z. Shunliang i Z. Dali, »Towards artificial intelligence enabled 6G: State of the art, challenges, and opportunities,« *Science Direct*, 2020.
- [2] I. Lam, »Medium,« 8 11 2023. [Mrežno]. Dostupno na: <https://medium.com/@irwinlam00/visualizing-neural-networks-2dd9ccb103ea>. [Pristupljeno 5. srpnja 2024.].
- [3] IBM, "Artificial Inteligence", dostupno online na: <https://www.ibm.com/topics/artificial-intelligence>. [Pristupljeno 5. srpanja 2024.].
- [4] IBM, "What is a neural network?", dostupno online na: <https://www.ibm.com/topics/neural-networks>. [Pristupljeno 6. srpanja 2024.].
- [5] Tenosrflow, dostupno online na: <https://www.tensorflow.org/>. [Pristupljeno 20. srpanja 2024].

6. POPIS SLIKA

Slika 2.1. Graf dopuštene sile $F[N]$ kao funkcije kontrakcije nominalne duljine $h[\%]$ pneumatskog mišića DMSP-5-100N	3
Slika 2.2. Grafički prikaz podataka za različite modele pneumatskog mišića	4
Slika 2.3. Korelacijska matrica za DMSP-5-100N	6
Slika 2.4. Korelacijska matrica za DMSP-10-100N	6
Slika 2.5. Korelacijska matrica za DMSP-20-200N	6
Slika 2.6. Korelacijska matrica za DMSP-40-400N	6
Slika 2.7. Korelacija podataka u zajedničkom skupu podataka	7
Slika 2.8. Histogram sile za DMSP-5-100N	8
Slika 2.9. Histogram sile za DMSP-10-100N	8
Slika 2.10. Histogram sile za DMSP-20-200N	8
Slika 2.11. Histogram sile za DMSP-40-400N	8
Slika 2.12. Histogram sile za zajednički skup	8
Slika 2.13. Histogram kontrakcije za DMSP-5-100N	9
Slika 2.14. Histogram kontrakcije za DMSP-10-100N	9
Slika 2.15. Histogram kontrakcije za DMSP-20-200N	9
Slika 2.16. Histogram kontrakcije za DMSP-40-400N	9
Slika 2.17. Histogram kontrakcije za zajednički skup	9
Slika 2.18. Arhitektura višeslojnog perceptrona [2]	10
Slika 2.19. Proces učenja neurona unutar mreže [3]	11
Slika 2.20. Linearna (identitetska) aktivacijska funkcija	12
Slika 2.21. Sigmoidna aktivacijska funkcija	13
Slika 2.22. Aktivacijska funkcija hiperbolički tangens	14
Slika 2.23. ReLU aktivacijska funkcija	14
Slika 2.24. Propusna ReLU aktivacijska funkcija	15
Slika 3.1. Funkcije gubitaka u treniranju i validaciji za model predikcije sile F za DMSP-5-100N model mišića	23
Slika 3.2. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije sile F za DMSP-5-100N model mišića	24
Slika 3.3. Distribucija iznosa apsolutnih pogrešaka za model predikcije sile F za DMSP-5-100N model mišića	25
Slika 3.4. Funkcije gubitaka u treniranju i validaciji za model predikcije kontrakcije h za DMSP-5-100N model mišića	26
Slika 3.5. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije kontrakcije h za DMSP-5-100N model mišića	27
Slika 3.6. Distribucija iznosa apsolutnih pogrešaka za model predikcije kontrakcije h za DMSP-5-100N model mišića	28
Slika 3.7. Funkcije gubitaka u treniranju i validaciji za model predikcije tlaka p za DMSP-5-100N model mišića	29
Slika 3.8. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije tlaka p za DMSP-5-100N model mišića	30
Slika 3.9. Distribucija iznosa apsolutnih pogrešaka za model predikcije tlaka p za DMSP-5-100N model mišića	30
Slika 3.10. Funkcije gubitaka u treniranju i validaciji za model predikcije sile F za DMSP-10-100N model mišića	33

Slika 3.11. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije sile F za DMSP-10-100N model mišića.....	34
Slika 3.12. Distribucija iznosa apsolutnih pogrešaka za model predikcije sile F za DMSP-10-100N model mišića	34
Slika 3.13. Funkcije gubitaka u treniranju i validaciji za model predikcije kontrakcije h za DMSP-10-100N model mišića	36
Slika 3.14. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije kontrakcije h za DMSP-10-100N model mišića	36
Slika 3.15. Distribucija iznosa apsolutnih pogrešaka za model predikcije kontrakcije h za DMSP-10-100N model mišića	37
Slika 3.16. Funkcije gubitaka u treniranju i validaciji za model predikcije tlaka p za DMSP-10-100N model mišića.....	39
Slika 3.17. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije tlaka p za DMSP-10-100N model mišića.....	39
Slika 3.18. Distribucija iznosa apsolutnih pogrešaka za model predikcije tlaka p za DMSP-10-100N model mišića.....	40
Slika 3.19. Funkcije gubitaka u treniranju i validaciji za model predikcije sile F za DMSP-20-200N model mišića	42
Slika 3.20. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije sile F za DMSP-20-200N model mišića.....	42
Slika 3.21. Distribucija iznosa apsolutnih pogrešaka za model predikcije sile F za DMSP-20-200N model mišića	43
Slika 3.22. Funkcije gubitaka u treniranju i validaciji za model predikcije kontrakcije h za DMSP-20-200N model mišića	44
Slika 3.23. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije kontrakcije h za DMSP-20-200N model mišića	45
Slika 3.24. Distribucija iznosa apsolutnih pogrešaka za model predikcije kontrakcije h za DMSP-20-200N model mišića	45
Slika 3.25. Funkcije gubitaka u treniranju i validaciji za model predikcije tlaka p za DMSP-20-200N model mišića.....	47
Slika 3.26. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije tlaka p za DMSP-20-200N model mišića.....	47
Slika 3.27. Distribucija iznosa apsolutnih pogrešaka za model predikcije tlaka p za DMSP-20-200N model mišića.....	48
Slika 3.28. Funkcije gubitaka u treniranju i validaciji za model predikcije sile F za DMSP-40-400N model mišića	50
Slika 3.29. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije sile F za DMSP-40-400N model mišića.....	50
Slika 3.30. Distribucija iznosa apsolutnih pogrešaka za model predikcije sile F za DMSP-40-400N model mišića	51
Slika 3.31. Funkcije gubitaka u treniranju i validaciji za model predikcije kontrakcije h za DMSP-40-400N model mišića	52
Slika 3.32. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije kontrakcije h za DMSP-40-400N model mišića	53
Slika 3.33. Distribucija iznosa apsolutnih pogrešaka za model predikcije kontrakcije h za DMSP-40-400N model mišića	53
Slika 3.34. Funkcije gubitaka u treniranju i validaciji za model predikcije tlaka p za DMSP-40-400N model mišića.....	55

Slika 3.35. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije tlaka p za DMSP-40-400N model mišića.....	55
Slika 3.36. Distribucija iznosa apsolutnih pogrešaka za model predikcije tlaka p za DMSP-40-400N model mišića.....	56
Slika 3.37. Funkcije gubitaka u treniranju i validaciji za model predikcije sile F za skupni set podataka	58
Slika 3.38. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije sile F za skupni set podataka	59
Slika 3.39. Distribucija iznosa apsolutnih pogrešaka za model predikcije sile F za skupni set podataka	59
Slika 3.40. Funkcije gubitaka u treniranju i validaciji za model predikcije kontrakcije h za skupni set podataka.....	61
Slika 3.41. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije kontrakcije h za skupni set podataka.....	61
Slika 3.42. Distribucija iznosa apsolutnih pogrešaka za model predikcije kontrakcije h za skupni set podataka.....	62
Slika 3.43. Funkcije gubitaka u treniranju i validaciji za model predikcije tlaka p za skupni set podataka	63
Slika 3.44. Devijacija predviđenih vrijednosti modela od stvarnih vrijednosti testnog skupa za model predikcije tlaka p za skupni set podataka	64
Slika 3.45. Distribucija iznosa apsolutnih pogrešaka za model predikcije tlaka p za skupni set podataka	64

7. POPIS TABLICA

Tablica 2.1. Zajednički skup podataka za sve modele mišića.....	4
Tablica 2.2. Opisna statistika svih skupova podataka.....	5
Tablica 3.1. Arhitektura modela za predikciju sile F za DMSP-5-100N model mišića.....	22
Tablica 3.2. Numerički rezultati performansi modela za predikciju sile F za DMSP-5-100N model mišića	23
Tablica 3.4. Arhitektura modela za predikciju kontrakcije h za DMSP-5-100N model mišića ...	25
Tablica 3.5. Numerički rezultati performansi modela za predikciju kontrakcije h za DMSP-5-100N	26
Tablica 3.7. Arhitektura modela za predikciju tlaka p za DMSP-5-100N model mišića.....	28
Tablica 3.8. Numerički rezultati performansi modela za predikciju tlaka p za DMSP-5-100N ...	29
Tablica 3.10. Arhitektura modela za predikciju sile F za DMSP-10-100N model mišića.....	32
Tablica 3.11. Numerički rezultati performansi modela za predikciju sile F za DMSP-10-100N model mišića	32
Tablica 3.13. Arhitektura modela za predikciju kontrakcije h za DMSP-10-100N model mišića	35
Tablica 3.14. Numerički rezultati performansi modela za predikciju kontrakcije h za DMSP-10-100N model mišića.....	35
Tablica 3.16. Arhitektura modela za predikciju tlaka p za DMSP-10-100N model mišića.....	38
Tablica 3.17. Numerički rezultati performansi modela za predikciju tlaka p za DMSP-10-100N model mišića	38
Tablica 3.19. Arhitektura modela za predikciju sile F za DMSP-20-200N model mišića.....	41
Tablica 3.20. Numerički rezultati performansi modela za predikciju sile F za DMSP-20-200N model mišića	41
Tablica 3.22. Arhitektura modela za predikciju kontrakcije h za DMSP-20-200N model mišića	43
Tablica 3.23. Numerički rezultati performansi modela za predikciju kontrakcije h za DMSP-20-200N model mišića.....	44
Tablica 3.25. Arhitektura modela za predikciju tlaka p za DMSP-20-200N model mišića.....	46
Tablica 3.26. Numerički rezultati performansi modela za predikciju tlaka p za DMSP-20-200N model mišića	46
Tablica 3.28. Arhitektura modela za predikciju sile F za DMSP-40-400N model mišića.....	49
Tablica 3.29. Numerički rezultati performansi modela za predikciju sile F za DMSP-40-400N model mišića	49
Tablica 3.31. Arhitektura modela za predikciju kontrakcije h za DMSP-40-400N model mišića	51
Tablica 3.32. Numerički rezultati performansi modela za predikciju kontrakcije h za DMSP-40-400N model mišića.....	52
Tablica 3.34. Arhitektura modela za predikciju tlaka p za DMSP-40-400N model mišića.....	54
Tablica 3.35. Numerički rezultati performansi modela za predikciju tlaka p za DMSP-40-400N model mišića	54
Tablica 3.37. Arhitektura modela za predikciju sile F za skupni set podataka	57
Tablica 3.38. Numerički rezultati performansi modela za predikciju sile F za skupni set podataka	57
Tablica 3.40. Arhitektura modela za predikciju kontrakcije h za skupni set podataka.....	60
Tablica 3.41. Numerički rezultati performansi modela za predikciju kontrakcije h za skupni set podataka	60
Tablica 3.43. Arhitektura modela za predikciju tlaka p za skupni set podataka	62

Tablica 3.44. Numerički rezultati performansi modela za predikciju tlaka p za skupni set podataka 63

8. SAŽETAK I KLJUČNE RIJEČI

Ovaj rad detaljno predstavlja regresijsko modeliranje različitih tipova pneumatskih mišića korištenjem umjetnih neuronskih mreža. Pneumatski mišići, poznati po svojoj laganoj strukturi i visokom omjeru snage i težine, sve se više korite u robotici i biomedicinskim primjenama. Međutim, njihovo nelinearno i složeno ponašanje predstavlja značajne izazove u točnom modeliranju i kontroli.

U ovom radu, podaci su prikupljeni iz službenog tehničkog dokumenta proizvođača pneumatskog mišića. Ovi podaci korišteni su za treniranje modela višeslojnog perceptrona koji predviđaju silu, tlak i kontrakciju u nominalnoj dužini pneumatskog mišića, kao tri zasebna izlaza. Realizirano je 15 pojedinačnih modela, ciljajući četiri različita tipa mišića (5-100N, 10-100N, 20-200N, 40-400N), uključujući tri modela koja ciljaju skup podataka sastavljen od sva četiri tipa mišića istovremeno.

Rezultati pokazuju da je moguće postići određenu razinu regresijske točnosti koristeći samo modele višeslojnog perceptrona, posebno s modelom treniranim na kombiniranom skupu podataka koji daje nešto bolje rezultate od ostalih. Ipak, još uvijek postoje mogućnosti za poboljšanje koje bi mogle značajno povećati performanse modela, poput odabira različitih drugih tipova modela umjetne inteligencije i bolje kvalitete prikupljanja podataka.

Ključne riječi: pneumatski mišić; umjetna inteligencija; strojno učenje; višeslojni perceptron;

9. ABSTRACT AND KEYWORDS

This thesis presents a detailed study on the regression modelling of different types of pneumatic muscles using artificial neural network. Pneumatic muscles, known for their lightweight structure and high power-to-weight ratio, are increasingly utilized in robotics and biomedical applications. However, their nonlinear and complex behaviour poses significant challenges in accurate modelling and control.

In this thesis the dataset is collected from the fluidic muscle datasheet. This dataset is then used to train multilayer perceptron models predicting the force, pressure, and contraction in nominal length of the fluidic muscle, as three separate outputs. 15 individual models are built, targeting four different types of fluidic muscles (5-100N, 10-100N, 20-200N, 40-400N), including three models targeting dataset comprised of all four muscle types at the same time.

The results show that it is possible to reach certain quality of regression accuracy using only multilayer perceptron models, especially with model trained on combined dataset which performs slightly better than others. On the other hand, there are still improvement options which could significantly increase model performance, like choosing different types of artificial intelligence models and better dataset collection quality.

Keywords: pneumatic muscles; artificial intelligence; machine learning; multilayer perceptron