

Skalabilni model hidrauličke pumpe temeljen na umjetnoj neuronskoj mreži

Ćavar, Luka

Undergraduate thesis / Završni rad

2024

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

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:235:191629>

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

Download date / Datum preuzimanja: **2024-11-24**

Repository / Repozitorij:

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



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Luka Čavar

Zagreb, 2024

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mentor:

Doc. dr. sc. Mihael Cipek, dipl. ing.

Student:

Luka Čavar

Zagreb, 2024.

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

Zahvaljujem se dr. sc. Mihaelu Cipeku na savjetima za najbrži i najbolji način izrade ovoga rada.

Također se zahvaljujem svojim roditeljima, sestrama te ostaloj bližoj rodbini, prijateljima i djevojci svim lijepim trenucima i podršci.

Luka Čavar



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



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

Sveučilište u Zagrebu	
Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa: 602 – 04 / 24 – 06 / 1	
Ur.broj: 15 – 24 –	

ZAVRŠNI ZADATAK

Student: **Luka Čavar** JMBAG: **0035231673**

Naslov rada na hrvatskom jeziku: **Skalabilni model hidrauličke pumpe temeljen na umjetnoj neuronskoj mreži**

Naslov rada na engleskom jeziku: **Scalable hydraulic pump model based on artificial neural network**

Opis zadatka:

Efikasnost hidrauličkog sustava uvelike ovisi o dimenzijama njegovih komponenti. Stoga se kod optimalnog dimenzioniranja hidrauličkog sustava koriste modeli koji vjerno opisuju gubitke za širok raspon veličina komponentata. Jedna od glavnih komponenti hidrauličkog sustava je hidrostatička crpka odnosno hidraulička pumpa. Imajući to u vidu, ovaj zadatak predlaže ispitivanje novog pristupa metodologiji dimenzioniranja hidrauličke pumpe koristeći model crne kutije koji se temelji na umjetnoj neuronskoj mreži. U radu je potrebno:

- Dati pregled različitih konfiguracija hidrauličkih pumpi, te opisati glavne karakteristike vezane uz efikasnost.
- Opisati model crne kutije koji se temelji na umjetnoj neuronskoj mreži.
- Koristeći kataloške podatke za jednu seriju pumpe, izraditi skalabilni model efikasnosti temeljen na umjetnoj neuronskoj mreži.
- Rezultate dobivene modelom usporediti s kataloškim podacima za različite veličine pumpe iste serije.
- Na temelju rezultata dati zaključak.

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

Zadatak zadan:

24. 4. 2024.

Datum predaje rada:

2. rok (izvanredni): 11. 7. 2024.
3. rok: 19. i 20. 9. 2024.

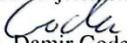
Predvideni datumi obrane:

2. rok (izvanredni): 15. 7. 2024.
3. rok: 23. 9. – 27. 9. 2024.

Zadatak zadao:


doc. dr. sc. Mihael Cipek

Predsjednik Povjerenstva:


prof. dr. sc. Damir Godec

SADRŽAJ

SADRŽAJ	1
POPIS SLIKA	2
POPIS TABLICA.....	4
POPIS OZNAKA	5
1. UVOD.....	8
2. PODJELA HIDRAULIČKIH PUMPI.....	9
2.1. Rotacijske pumpe	10
2.1.1. Zupčaste hidrauličke pumpe	10
2.1.2. Vijčane hidrauličke pumpe	11
2.1.3. Krilna hidraulička pumpa.....	11
2.1.4. Klipna hidraulička pumpa.....	12
2.2. Linearne pumpe.....	13
3. EFIKASNOST HIDRAULIČKIH PUMPI	14
4. MODEL CRNE KUTIJE TEMELJEN NA NEURONSKOJ MREŽI	17
4.1. Osnovni model neuronske mreže	17
4.2. Pristupi učenja neuronskih mreža	19
4.3. Tipovi neuronskih mreža	20
4.4. Prednosti i nedostaci neuronskih mreža.....	23
5. IZRADA MODELA NEURONSKE MREŽE ZA PREDVIĐANJE EFIKASNOSTI HIDRAULIČKU PUMPU.....	24
5.1. Kataloški podaci.....	24
5.2. Struktura neuronske mreže za predviđanje efikasnosti.....	25
5.3. Pristup i analizi zadatka	26
6. REZULTATI ANALIZE	27
6.1. Predviđanja na modelima H25 i H31	27
6.2. Predviđanja na modelima H39 i H49.....	32
6.3. Predviđanja na modelima H49 i H62.....	37
6.4. Predviđanja na modelima H77 i H90.....	42
6.5. Diskusija.....	47
7. ZAKLJUČAK.....	48
LITERATURA.....	49

POPIS SLIKA

Slika 1. Podjela hidrauličkih pumpi prema izvedbi [4].....	9
Slika 2. Presjek zupčaste hidrauličke pumpe s unutarnjim i vanjskim ozubljenjem [5].....	10
Slika 3. Hidraulička klipna pumpa sa nagibnom pločom [7].....	12
Slika 4. Shematski prikaz gubitaka hidrauličkog sustava[8].....	14
Slika 5. Karakteristike zupčanih hidraulički pumpi [9]	15
Slika 6. Karakteristike krilnih hidrauličkih pumpi [9]	16
Slika 7. Karakteristike klipnih hidrauličkih pumpi [9]	16
Slika 8. Biološki neuron i njegov prikaz u računalnoj arhitekturi [12].....	17
Slika 9. Najčešće korištene aktivacijske funkcije [13].....	19
Slika 10. Model statički neuron [13].....	20
Slika 11. Model dinamičkog neurona [14].....	21
Slika 12. Konvolucijska neuronska mreža [16]	21
Slika 13. Rekurentna neuronska mreža [17]	22
Slika 14. RBF neuronska mreža [15]	23
Slika 15. Prikaz osnovne strukture neuronske mreže [18]	25
Slika 16. Usporedba stvarnih i predviđenih vrijednosti modela	27
Slika 17. Mapa učinkovitosti pumpe H25	28
Slika 18. Predviđena mapa učinkovitosti za pumpu H25.....	28
Slika 19. Pogreška modela za pumpu H25.....	29
Slika 20. Mapa učinkovitosti pumpe H31	29
Slika 21. Predviđena mapa učinkovitosti za pumpu H31.....	30
Slika 22. Pogreška modela za pumpu H31	30
Slika 23. NRMS za model neuronske mreže br.1	31
Slika 24. Utjecaj broja neurona na ukupni MSE.....	31
Slika 25. Usporedba stvarnih i predviđenih vrijednosti modela	32
Slika 26. Mapa učinkovitosti pumpe H39	33
Slika 27. Predviđena mapa učinkovitosti za pumpu H31.....	33
Slika 28. Pogreška modela za pumpu H39.....	34
Slika 29. Mapa učinkovitosti pumpe H49	34
Slika 30. Predviđena mapa učinkovitosti za pumpu H49.....	35
Slika 31. Pogreška modela za pumpu H39.....	35
Slika 32. NRMS za model neuronske mreže br.2	36
Slika 33. Utjecaj broja neurona na ukupni MSE.....	36
Slika 34. Usporedba stvarnih i predviđenih vrijednosti modela	37
Slika 35. Mapa učinkovitosti pumpe H49	38
Slika 36. Predviđena mapa učinkovitosti za pumpu H49.....	38
Slika 37. Pogreška modela za pumpu H39.....	39
Slika 38. Mapa učinkovitosti pumpe H62	39
Slika 39. Predviđena mapa učinkovitosti za pumpu H62.....	40
Slika 40. Pogreška modela za pumpu H62.....	40
Slika 41. NRMS za model neuronske mreže br.3	41
Slika 42. Utjecaj broja neurona na ukupni MSE.....	41
Slika 43. Usporedba stvarnih i predviđenih vrijednosti modela	42
Slika 44. Mapa učinkovitosti pumpe H77	43
Slika 45. Predviđena mapa učinkovitosti za pumpu H77.....	43
Slika 46. Pogreška modela za pumpu H77.....	44
Slika 47. Mapa učinkovitosti pumpe H90.....	44
Slika 48. Predviđena mapa učinkovitosti za pumpu H90.....	45

Slika 49. Pogreška modela za pumpu H77	45
Slika 50. NRMS za model neuronske mreže br.4	46
Slika 51. Utjecaj broja neurona na ukupni MSE	46

POPIS TABLICA

Tablica 1. Vrijednosti [2] 24
Tablica 2. Greška modela neuronske mreže..... 47

POPIS OZNAKA

Oznaka	Jedinica	Opis
η_{tot}	-	ukupna učinkovitost
η_{mt}	-	hidrodinamička efikasnost
η_{vol}	-	volumetrijska efikasnost
Q	m^3/s	protok
Q_t	m^3/s	volumetrijskog protoka
Q_l	m^3/s	volumenski gubici curenjem
D	m^3	istiskljivost
p	bar	tlak
τ	Nm	moment
V	m^3	volumen
P_o	W	izlazna snaga
ω	okr/min	kutna brzina vrtnje
P_i	W	ulazna snaga

SAŽETAK

Ovaj rad bavi se razvojem skalabilnog modela neuronske mreže za predviđanje efikasnosti hidrauličke pumpe. Korištenjem MATLAB okruženja, cilj je bio kreirati model koji može efikasno obrađivati različite veličine i složenosti podataka bez gubitka performansi. Kroz analizu različitih arhitektura mreža, testirani su modeli na više skupova podataka kako bi se procijenila njihova sposobnost prilagođavanja. Četiri modela neuronske mreže su stvorena s obzirom na specifičnosti podataka i način pristupa s obzirom da su modeli trenirani na različitim dimenzijama pumpa kako bi se usporedila efikasnost i skalabilnost svakog modela, pri čemu je također dan uvid koliko je model neuronske mreže adekvatan za rješavanje problema predviđanja efikasnosti hidrauličke pumpe.

Ključne riječi: Skalabilni model, neuronska mreža, MATLAB, predviđanje efikasnosti, hidraulička pumpa, arhitektura mreža, obrada podataka, skalabilnost, performanse modela.

SUMMARY

This study deals with the development of a scalable neural network model for predicting the efficiency of a hydraulic pump. Using the MATLAB environment, the aim was to create a model capable of efficiently processing different sizes and complexities of data without loss of performance. Through the analysis of various network architectures, the models were tested on multiple datasets to assess their adaptability. Four neural network models were created based on the specific data characteristics and approach, considering that the models were trained on different pump dimensions to compare the efficiency and scalability of each model. Additionally, insight was provided into how well the neural network model is suited for solving the problem of predicting hydraulic pump efficiency.

Keywords: Scalable model, neural network, MATLAB, efficiency prediction, hydraulic pump, network architecture, data processing, scalability, model performance.

1. UVOD

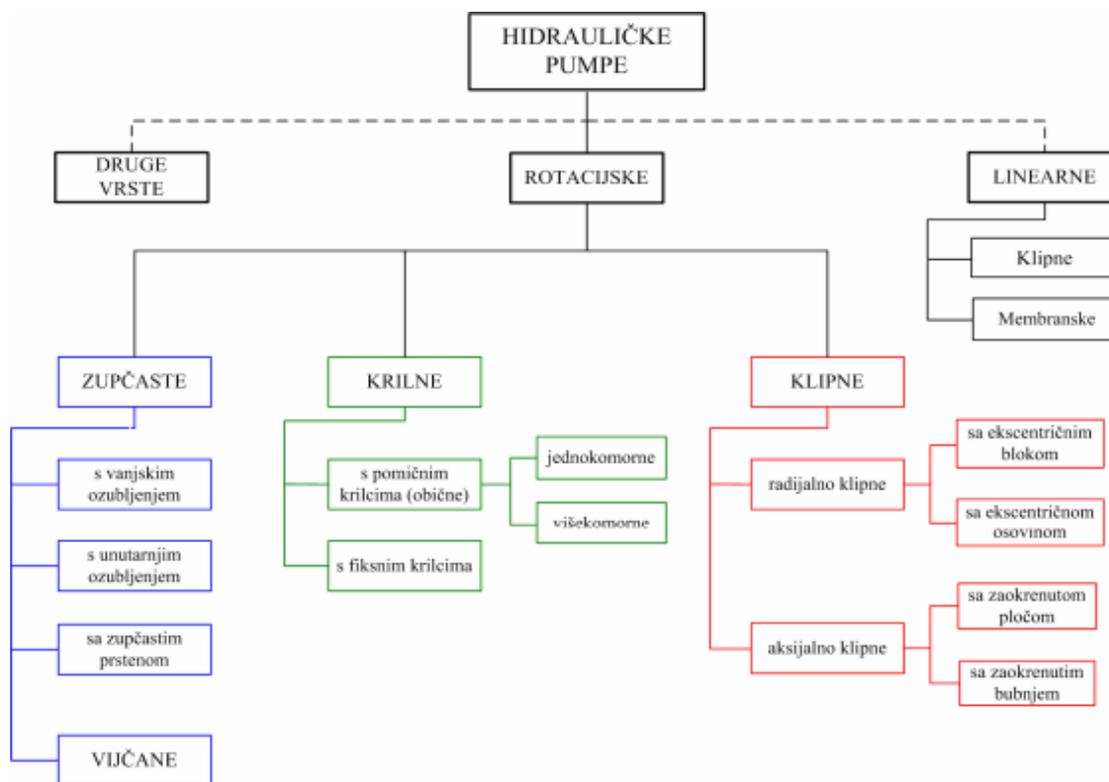
U modernim industrijskim procesima, hidraulički sustavi igraju ključnu ulogu u prijenosu snage i obavljanju različitih mehaničkih zadataka. Jedan od ključnih elemenata svakog hidrauličkog sustava je hidraulička pumpa, koja pretvara mehaničku energiju u hidrauličku, zbog čega njena učinkovitost ima izravan utjecaj na ukupne performanse cijelog sustava, kao i na ekonomičnost njegove primjene [1]. S obzirom na sve strože zahtjeve za energetsom efikasnošću i smanjenjem troškova održavanja, postaje ključno razvijati metode koje mogu precizno predviđati efikasnost rada hidrauličkih pumpi. Predviđanje takvih performansi može pomoći u optimizaciji rada, prepoznavanju potencijalnih problema i smanjenju troškova održavanja te osigurati kontinuirani i pouzdani rad sustava.

Neuronske mreže, kao dio šireg područja umjetne inteligencije, postaju sve popularniji alat za rješavanje složenih inženjerskih problema. Njihova sposobnost modeliranja složenih, nelinearnih odnosa između ulaznih i izlaznih varijabli čini ih vrlo pogodnima za primjene poput predviđanja efikasnosti hidrauličke pumpe. Tradicionalne metode predviđanja često se oslanjaju na jednostavne linearne modele koji ne mogu u potpunosti obuhvatiti sve faktore koji utječu na učinkovitost rada pumpe, dok neuronske mreže koriste napredne tehnike učenja iz različitih podataka kako bi bolje razumjele međusobne odnose između njih, te njihove veze predstavila parametrima [2].

Ovaj rad daje kratak uvid u konfiguracije hidraulički pumpi uz karakteristike efikasnosti pri radu, štoviše opisane je model neuronske mreže koji je ključan za eksperimentalni dio u kojem se istražuje učinkovitost neuronskih mreža u predviđanju efikasnosti hidrauličkih pumpi, pri čemu se analizira utjecaj odabrane arhitekture i parametara koji mogu poboljšati preciznost predviđanja. Korištenjem kataloških podataka o radu jedne serije hidrauličkih pumpi, neuronska mreža trenira se za prepoznavanje obrazaca u podacima iz skupa za učenje, a zatim se koristi za predviđanje performansi koji daju uvid u efikasnost ovog pristupa.

2. PODJELA HIDRAULIČKIH PUMPI

Osnovna podjela pumpi prema načinu pretvorbe mehaničke energije u hidrauličku energiju fluida je: hidrostatička i hidrodinamička pumpa. Hidrostatičke pumpe rade na principu smanjenja volumena u komori, pri čemu se ostvaruje povećan tlak i protok koji je jednak volumenu jednog okreta i njoj brzini vrtnje. Također, zbog same izvedbe omogućuju preciznu kontrolu protoka i tlaka, zbog čega se koriste u sustavima gdje je potrebna visoka učinkovitost. S druge strane su hidrodinamičke pumpe, poznate kao turbopumpe, koje preko pokretnih lopatica ostvaruju povećanje protoka i pritiska fluida kroz sustav. Ove pumpe su učinkovite za visoke protoke pri nižim tlakovima, karakteristične za raketne motore koji kombiniraju centrifugalno i aksijalno djelovanje za optimalnu učinkovitost [3].



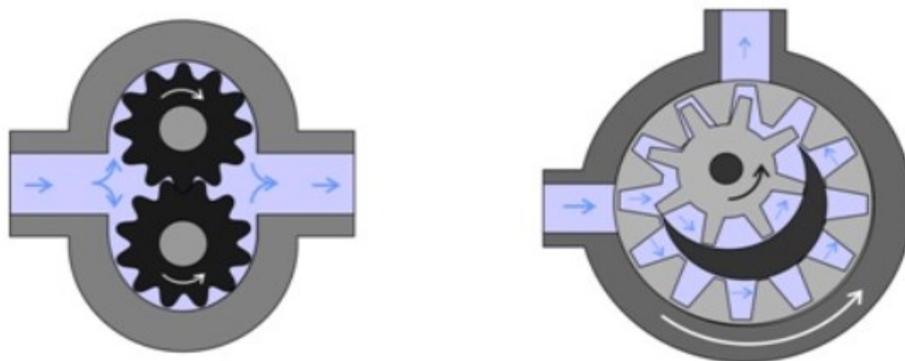
Slika 1. Podjela hidrauličkih pumpi prema izvedbi [4]

2.1. Rotacijske pumpe

Rotacijske pumpe prenose energiju tekućini i stvaraju protok zahvaljujući rotaciji impelera ili rotora, koji omogućava usisavanje i istiskivanje tekućine. Ove pumpe osiguravaju stalan i ravnomjeran protok, te se odlikuju visokom efikasnošću i sposobnošću da rukovode tekućinama većeg viskoziteta [3].

2.1.1. Zupčaste hidrauličke pumpe

Zupčaste hidrauličke pumpe spadaju u kategoriju pumpa s pozitivnim pomakom s obzirom da potiskuju tekućinu uzastopnim zatvaranjem fiksnog volumena pomoću međusobno usklađenih zupčanika, koji postižu brtvljenje tekućine s kućištem pumpe stvarajući usis na ulazu pumpe. Tekućina zatim putuje unutar šupljina rotirajućih zupčanika prema ispustu. Prema konfiguraciji zupčaste hidrauličke pumpe mogu biti sa vanjskim ili unutarnjim ozubljenjem sa dodatnim zupčastim prstenom ili srpastim uloškom [3, 5]. Na slici 2 prikazani su poprečni presjeci zupčaste pumpe s vanjskim i unutarnjim ozubljenjem, koje spadaju u kategoriju hidrauličkih rotacijskih pumpi.



Slika 2. Presjek zupčaste hidrauličke pumpe s unutarnjim i vanjskim ozubljenjem [5]

Kod pumpe s vanjskim ozubljenjem jedan zupčanik pokreće motor, dok se drugi rotira ovisno o prvome, također je važno napomenuti da su zupčanici jednakih dimenzija sa naglaskom na preciznu toleranciju između zupčanika, kako ne bi došlo do povrata tekućine kroz središte prema usisnoj grani. Ovisno o izradi vanjskih zubi, također postoje pumpe sa; ravnim, kosim, cilindričnim i spiralnim vanjskim ozubljenjem. S druge strane pumpe s unutarnjim ozubljenjem rade na istom principu samo je vanjski zupčanik s unutarnjim ozubljenjem onaj koji je spojen na motor, dok unutarnji zupčanik koji je postavljen izvan središta rotira tako da se zubi konstantno dodiruju u jednoj točki [3,5].

Štoviše, zupčaste hidrauličke pumpe se razlikuju s obzirom na efikasnost te primjenu u industriji. Zupčaste hidrauličke pumpe s vanjskim ozubljenjem se ističu po tome što podnose visoke tlakove i brzine protoka zbog čvršćih oslonaca i tolerancija same konstrukcije, koja se ističe svojom jednostavnošću i niskom cijenom, međutim imaju velike volumetrijske gubitke zbog čega im se stupanj korisnog djelovanja kreće od 75 - 85%. S druge strane pumpe s unutarnjim ozubljenjem, imaju veću usisnu silu, te su prikladne za tekućine s povećanom viskoznosti. Budući da imaju složeniju konstrukciju odlikuju se tihim radom i visokom efikasnosti koja se kreće između 85% i 95% ovisno o dizajnu pumpe i uvjetima rada [3, 5].

2.1.2. Vijčane hidrauličke pumpe

Vijčane hidrauličke pumpe odlikuju se raznim konfiguracijama izvedbe, ali sa minimalno 2 vretena, kod kojih tekućina ulazi u navoj početnog ili usisnog vratila, te ulazi u prostor između navoja drugog vratila, pri čemu se potiskuje tekućina u ispusnu stranu pumpe. Karakteristične su po svojstvima kao što su tihi rad, ujednačen protok i tlak kroz radne cikluse, te ravnomjeran pogonski moment uz širok raspon protoka. Štoviše, zbog velike zračnosti među vretenima gubitci su veliki, stoga je stupanj korisnog djelovanja manji od 80%, te se pumpa primjenjuje u sustavima s nižim tlakom do 100 bara. Čestu primjenu pronalazi u naftnoj industriji, u sustavima podmazivanja i prijenosa goriva [3].

2.1.3. Krilna hidraulička pumpa

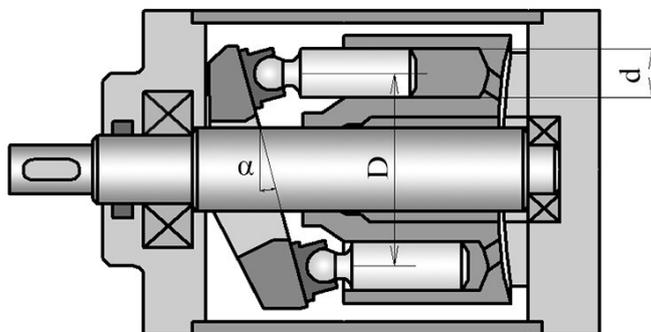
Krilna ili lamelna hidraulička pumpa koriste lamele postavljene u rotoru, koji je ekscentrično smješten u statoru, tako da tijekom rotacije radne komore povećavaju volumen u prvoj polovici okreta, pri čemu je omogućen usis, dok je u drugoj polovici omogućeno tlačenje. Štoviše, protok se može kontrolirati promjenom ekscentričnosti rotora, zbog čega postoje složenije izvedbe pumpe s konstantnim protokom, koje mogu biti jednoradne ili višeradne. Također, postoje izvedbe krilnih pumpi s fiksnim lamelama koje su nepomične unutar statora, dok se rotor rotira osiguran je konstantan protok uz stalni volumen radne komore tijekom rotacije. Važno je napomenuti da su obe izvedbe pumpe poznate po mirnom radu i imaju stupanj djelovanja između 60% i 90% [3].

2.1.4. Klipna hidraulička pumpa

Klipna pumpa spada pod rotacijske hidrauličke pumpe koje koriste princip recipročnog kretanja za stvaranje protoka tekućine, pri čemu umjesto jednog klipa koriste kombinacije s više klipova i cilindara. Dio mehanizma pumpe rotira oko pogonske osovine kako bi generirao recipročna kretanja koja uvlače tekućinu u svaki cilindar i zatim je izbacuju, stvarajući protok. Postoje dvije osnovne vrste: aksijalne i radijalne klipne pumpe, koje mogu biti s fiksnim ili promjenjivim pomakom [3].

Radijalne hidrauličke klipne pumpe mogu imati unutarnji ili vanjski ekscentar koji određuje način rada. Kod pumpi s vanjskim ekscentrom, smještenim između statora i rotora, hod klipova omogućuje usis i tlačenje fluida, a protok se može regulirati promjenom ekscentriciteta. Nasuprot tome, kod pumpi s unutarnjim ekscentrom cilindarski blok je statičan, dok se vratilo rotira, omogućujući usis i tlačenje fluida preko nepovratnih ventila, ali bez mogućnosti regulacije protoka. Klipno radijalne hidrauličke pumpe karakteristične su po visokoj učinkovitosti koja se može kretati od 85% do 95% u optimalnim uvjetima rada, zatim visokim radnim tlakom koji ide do 1000 bara uz niske protok, također nema unutarnjih sila na ležaju pogonskog vratila, što omogućuje visoku pouzdanost rada s niskim razinama buke [3,6].

Hidrauličke aksijalne klipne pumpe imaju klipove raspoređene paralelno s osi rotacije, a cilindarski blok, koji obično sadrži neparan broj cilindara, omogućuje stvaranje visokog pritiska i protoka prema potrebama sustava. Prema konstrukciji i načinu rada razlikuju se pumpe s nagibnom pločom i pumpe s nagibnom osi [3,6].



Slika 3. Hidraulička klipna pumpa sa nagibnom pločom [7]

Hidrauličke klipne pumpe s nagibnom pločom koriste ploču koja miruje pod kutom u odnosu na os rotacije, na koju su spojeni klipovi preko ležajeva. Klipovi izvode usis fluida u prvoj polovici rotacije vratila i tlačenje u drugoj polovici. Kut nagibne ploče ključan je za regulaciju protoka; promjena kuta utječe na hod cilindra i time na protok. Kut ploče može doseći 90° za zaustavljanje protoka, dok prelazak preko tog kuta omogućuje protok u suprotnom smjeru. S druge strane, hidrauličke klipne pumpe s nagibnom osi koriste osovinu postavljenu pod kutom u odnosu na os cilindra, s prirubnicom koja omogućuje vezu s klipovima putem kardanskog zgloba. Kako se osovina rotira, klipovi usisavaju i tlače tekućinu ovisno o kutu između osovine i cilindra [3,6].

Aksijalne hidrauličke klipne pumpe s nagibnom pločom i nagibnom osi koriste se u srednje i visokotlačnim sustavima. Dostupne su u verzijama s promjenjivim i fiksnim obujmom. Pumpe s promjenjivim volumenom omogućuju podešavanje protoka promjenom kuta zakretanja, a koriste se u otvorenim i zatvorenim hidrostatskim krugovima. Pumpe s fiksnim volumenom imaju stalni pomak klipova, pa je protok proporcionalan brzini rotacije pogonske osovine i koriste se u otvorenim regulacijskim krugovima. Učinkovitost aksijalnih klipnih pumpi kreće se između 90% i 95%, što ih čini prikladnim za aplikacije koje zahtijevaju visoku snagu i pouzdanost [3,6].

2.2. Linearne pumpe

U ovu skupinu hidrauličkih pumpi spadaju membranske i klipne pumpe. Membranske pumpe koriste fleksibilnu membranu za stvaranje protoka tekućine, zbog čega učinkovito pumpaju tekućine s visokim viskozitetom, agresivne kemikalije, ili tekućine koje sadrže čestice. S druge strane klipne pumpe mogu biti sa koljeničastim i kulisnim mehanizmom, koji omogućuju preciznu kontrolu protoka i visok pritisak. Ovi tipovi hidrauličkih pumi rijetko se koriste u hidraulici zbog složenosti i ograničenja u uvjetima visokog tlaka. [3]

3. EFIKASNOST HIDRAULIČKIH PUMPI

Efikasnost hidrauličkih pumpi jedan je od osnovnih podataka, koji varira ovisno o vrsti pumpe i radnim uvjetima, te je ključan za smanjenje troškova i povećanje dugovječnosti sustava. Ukupni stupanj djelovanja hidrauličke pumpe opisan je izrazom:

$$\eta_{tot} = \eta_{mt} * \eta_{vol} \quad (1)$$

gdje je:

η_{mt} - hidrodinamička efikasnost

η_{vol} – volumetrijska efikasnost

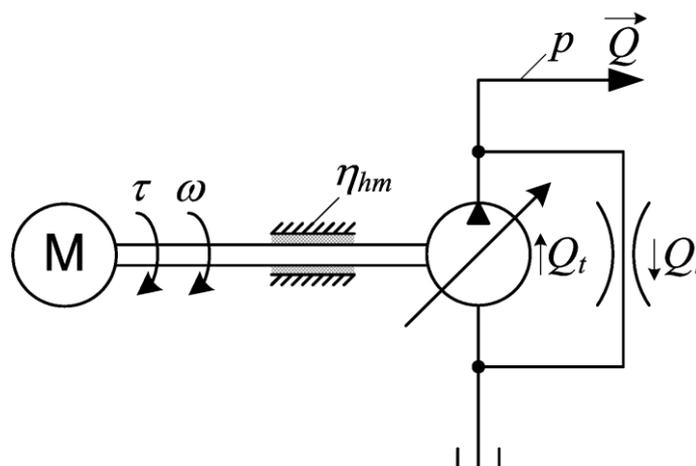
S obzirom na specifičnosti fluida u sustavu dolazi do gubitaka u volumenu tekućine zbog unutarnjih “curenja” u pumpi Q_l , zbog čega su ovi gubici opisani volumetrijskom efikasnosti koji je u izrazu prikazan oznakom η_{vol} , a dobijemo je sljedećim izrazom:

$$\eta_{vol} = \frac{(Q_t - Q_l)}{Q_t} = \frac{Q}{Q_t} \quad (2)$$

Osim volumetrijskih gubitaka značajni su i hidromehanički gubici koji uključuju gubitke viskoznog i mehaničkog trenja, te hidrodinamičke gubitke, a prikazani su oznakom η_{mt} , a dobije se na sljedeći način:

$$\eta_{mt} = \frac{D * p}{\tau} \quad (3)$$

Shematski prikaz ukupnih gubitaka je prikazan na slici 10. S obzirom na specifičnost hidrauličkih sustava dolazi do gubitaka u volumenu tekućine zbog volumetrijskih i hidrodinamičkih specifičnosti fluida.



Slika 4. Shematski prikaz gubitaka hidrauličkog sustava[8]

gdje su: D - istiskljivost, p - tlak u sustavu i τ - ulazni moment, pri čemu je izraz za istiskljivost jednak:

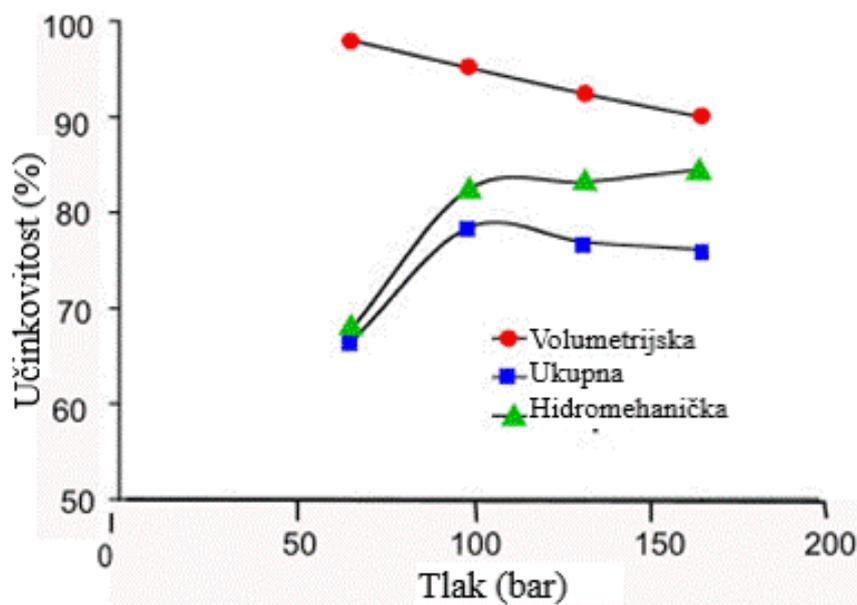
$$D = \frac{V}{2\pi} \quad (4)$$

gdje je V - volumen pumpe.

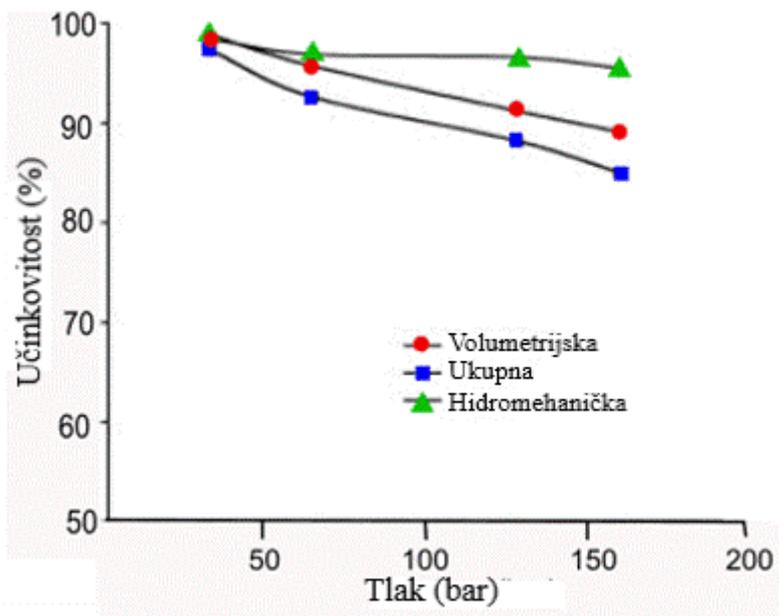
Također se preko navedenih izraza može doći do ukupnog prijenosa snage hidrauličke pumpe koji glasi:

$$P_o = \eta_{vol} * \eta_{mt} * \omega * \tau = \eta_{tot} * P_i \quad (5)$$

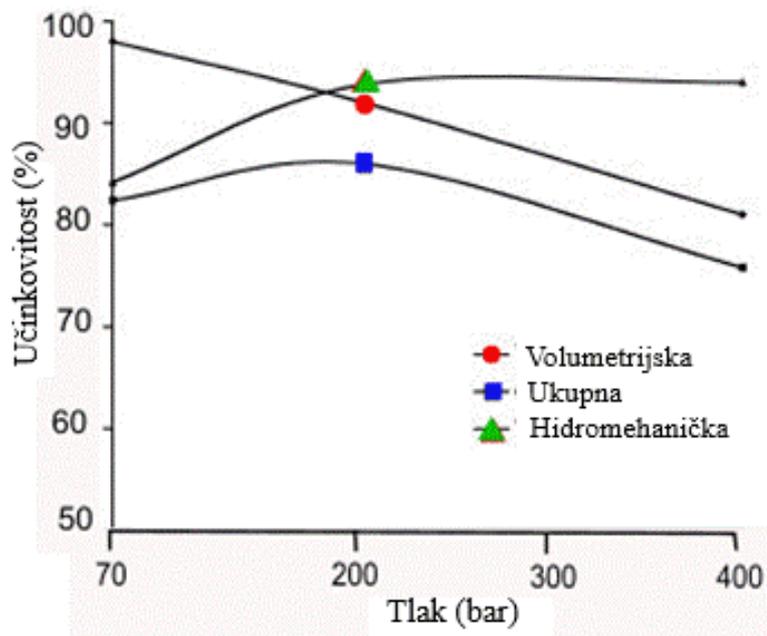
Štoviše, s obzirom na način rad, te specifične konstrukcijske karakteristike, efikasnosti i gubitci hidraulički pumpe pri nominalnoj brzini se vide na slikama 11-13.



Slika 5. Karakteristike zupčanih hidraulički pumpe [9]



Slika 6. Karakteristike krilnih hidrauličkih pumpi [9]



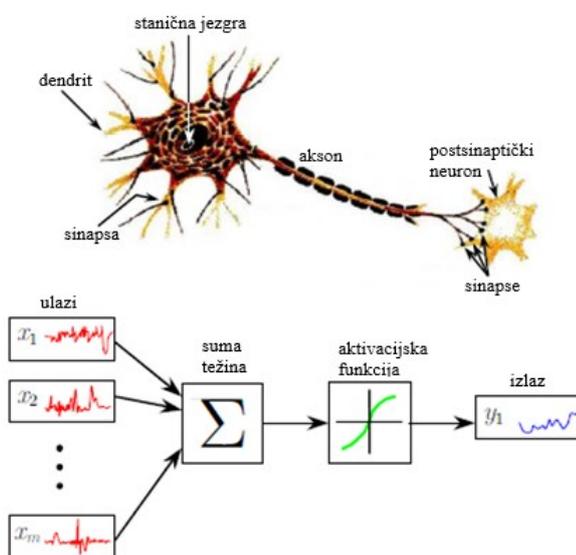
Slika 7. Karakteristike klipnih hidrauličkih pumpi [9]

4. MODEL CRNE KUTIJE TEMELJEN NA NEURONSKOJ MREŽI

U znanosti, računarstvu i inženjeringu, "black box" sustav se promatra kroz ulaze i izlaze bez uvida u unutarnje mehanizme preko kojih su povezani, a poznati su kao statistički ili modeli strojnog učenja kod kojih parametri modela nemaju fizičko značenje. Ovi modeli su privlačni zbog svoje fleksibilnosti i jednostavnosti izgradnje, koji koriste operativne podatke za treniranje internih parametara, no, kao što ime sugerira, u većini slučajeva black-box modeli djeluju samo kao promatrači, jer procijenjeni parametri imaju malo veze sa stvarnim fizičkim procesom. Dobro osmišljen black-box model može postići visoku točnost u predikciji stanja. Brz rast u području statističkog i strojnog učenja doveo je do sve većeg broja istraživanja o korištenju black-box modela u FDD (otkrivanje i dijagnostika grešaka) aplikacijama. Neki od uobičajenih primjera black-box modela uključuju aproksimaciju krivulja, umjetne neuronske mreže (ANN), analizu glavnih komponenti (PCA), strojne potpore vektorima (SVM) i druge [10].

4.1. Osnovni model neuronske mreže

Neuronska mreža je jedna od metoda u umjetnoj inteligenciji koja se smatra vrstom računalne arhitekture, jer se temelji na modelu funkcioniranja ljudskog mozga. Sastoji se od skupine procesnih jedinica zvanih "čvorovi", koji međusobno razmjenjuju podatke kao što neuroni u mozgu prenose električne impulse. Koristi se kao jedna od metoda u strojnom učenju za stvaranje računalnih programa koji uče bez specifičnih uputa, pri čemu je značajna princip dubokog učenja značajan za donošenje zaključke iz nepovezanih podataka bez ljudske intervencije [11].



Slika 8. Biološki neuron i njegov prikaz u računalnoj arhitekturi [12]

Struktura neuronske mreže sastavljena od skupa čvorova raspoređenih kroz najmanje tri sloja: ulazni sloj, "skriveni sloj" i izlazni sloj. U ulaznom sloju svaka značajka je predstavljena čvorom koji prima ulazne podatke. Svaki ulazni podatak se množi težinama koje predstavljaju jačinu veze među neuronima i oni se tijekom obuke mijenjaju u svrhu stvaranja optimalnog modela. Štoviše, u skrivenom sloju, se obrađuju ulazi tako da se množe težinama, zbrajaju se, te zatim propuštaju kroz aktivacijsku funkciju [13].

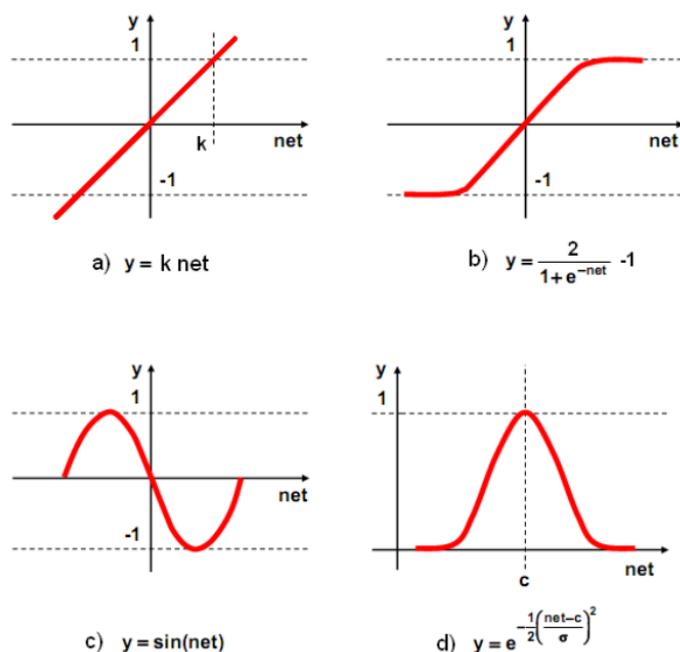
Time se uvodi nelinearnost, omogućujući mreži prepoznavanje složenih uzoraka, gdje se u konačnici rezultat dobije ponavljanjem postupka sve dok se ne dođe do odgovarajućeg uzorka na izlazu. Ovaj pristup generiranja modela neuronske mreže poznat je pod nazivom „prosljeđivanje unaprijed“, jer ne postoji povratna propagacija koja utječe na podešavanje težina. Kod pristupa sa povratnom propagacijom koristi se funkcija gubitaka preko koje se izlaz mreže uspoređuje s ciljanom vrijednosti, a za regresijske probleme često se koristi srednja kvadratna greška kao funkcija troška a glasi:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y})^2 \quad (6)$$

y_i - predstavlja stvarnu vrijednost i-tog podatka.

\hat{y} - predstavlja predviđenu vrijednost i-tog podatka.

Nakon funkcije gubitaka može se koristiti metoda gradijenta kod koje mreža koristi gradijentni spust, tako što derivira funkciju troška za svaku težinu, te zatim ažurira težina prema gradijentu kako bi se mreža optimizirala. Važno je napomenuti da se mreža iterativno prilagođava povratnom propagacijom, pri čemu je potrebna što veća količina podataka na ulazu kako bi se dobio što bolji model neuronske mreže. Modelu se uvodi nelinearnost pomoću aktivacijskih funkcija, preko koje se odlučuje hoće li se neuron "aktivirati", također ograničavaju vrijednosti u određenom rasponu, što pomaže stabilizaciji učenja. Aktivacijske funkcije iznad svega mogu utjecati na brzinu i način konvergencije tijekom treniranja mreže, a što se tiče izbora funkcije on ovisi o specifičnom problemu koji se rješava., arhitekturi mreže i prirodi podataka [13].



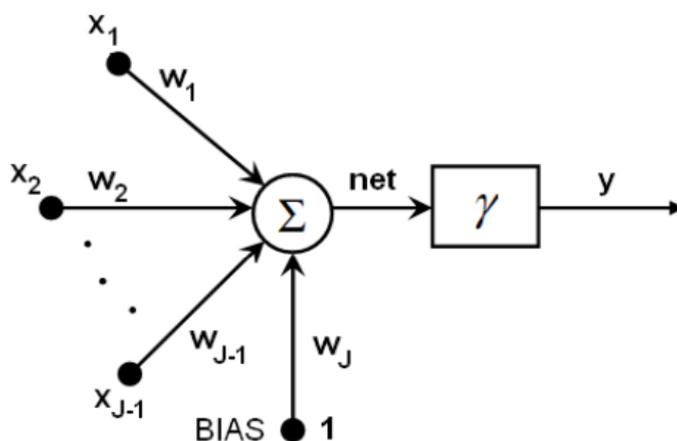
Slika 9. Najčešće korištene aktivacijske funkcije [14]

4.2. Pristupi učenja neuronskih mreža

S obzirom na pristup učenju neuronske mreže postoje tri načina učenja a to su: učenje s nadzorom, učenje bez nadzora i učenje s pojačanjem. Pristup učenja s nadzorom temelji se na tome da mreža uči pod vodstvom učitelja koji ima pristup parovima ulaza i izlaza, s obzirom na to mreža generira izlaze na temelju ulaza, a zatim uspoređuje te izlaze sa željenim izlazima koje zna učitelj. Na temelju razlike između tih vrijednosti generira se signalna pogreška, pri čemu se parametri iterativno prilagođavaju dok se pogreška na smanji na prihvatljivu razinu. S druge strane kod učenje bez nadzora ne postoje ekvivalentne izlazne varijable, pri čemu je cilj razumjeti temeljnu strukturu ulaznih podataka bez pomoći učitelja. Namjera je modeliranje obrazaca i odnosa među podacima, što se koristi kod stvaranja asocijacija i grupiranja skupa podataka u više klastera, pri čemu su podaci unutar svakog klastera slični jedni drugima, dok je učenje s nadzorom karakteristično za pojmove kao što su regresija i klasifikacija. Osim ovih pristupa sve veću primjenu pronalazi učenje putem pojačanja, gdje mreža stječe znanje putem interakcije s okolinom i povratnih informacija u obliku nagrada i kazni. Cilj je pronaći strategiju koja maksimizira kumulativne nagrade tijekom vremena. Ovu vrsta učenja često se koristi u igrama i primjenama koje zahtijevaju donošenje odluka [13].

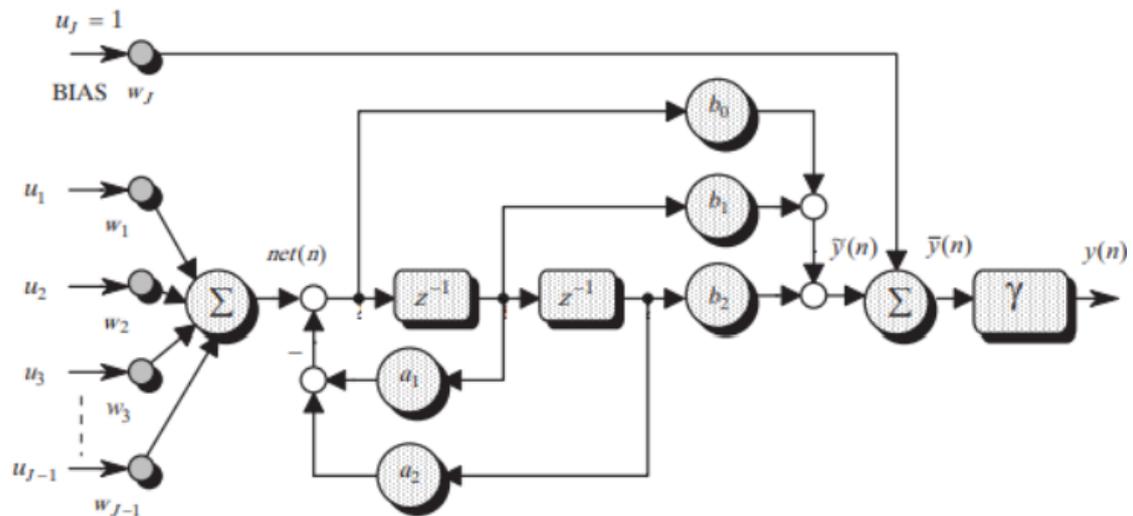
4.3. Tipovi neuronskih mreža

Tipovi neuronskih mreža razlikuju se prema kompleksnosti arhitekture neuronske mreže i načinu modeliranja neuronske mreže. Štoviše, s obzirom na kompleksnost arhitekture razlikuju se jednostavne mreže koje obično imaju jedan skriveni sloj i duboke neuronske mreže sadrže više skrivenih slojeva, zbog čega su zaduženi za složenije zadatke. Kod modeliranja neuronske mreže razlikujemo statičke i dinamičke neuronske mreže.



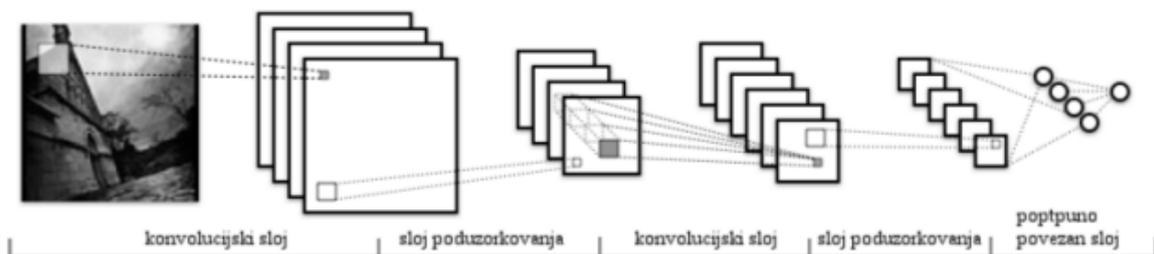
Slika 10. Model statički neuron [14]

Statička unaprijedna neuronska mreža jedna je od najpoznatijih modela koji se koristi za opisivanje statičkih, a dijelom i dinamičkih problema, s obzirom da nemaju povratne veze pogodne su za rješavanje jednostavnijih problema poput regresijske i prepoznavanju uzoraka. Sastoje se od više ulaza, funkcije za sumu, aktivacijske funkcije te jednog izlaza, pri čemu je značajan jedinični neuron BIAS na ulazu, koji je potreban kako bi mreža uopće mogla učiti, te je važno napomenuti da se povećavanjem skrivenih slojeva, svaki sloj proširuje za jedan BIAS [14].



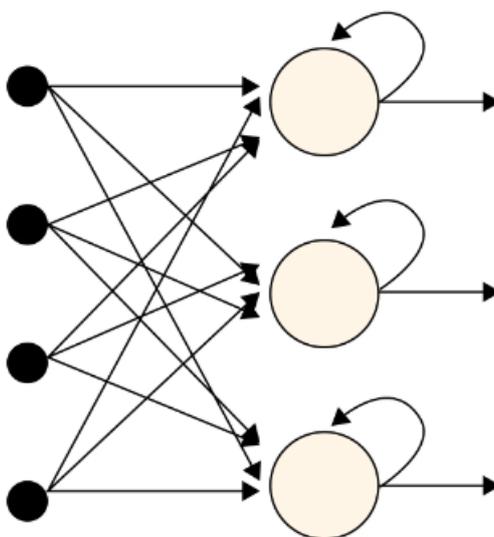
Slika 11. Model dinamičkog neurona [15]

U modelu dinamičkog neurona, postoji povratna veza koja osigurava da aktivnost neurona ovisi o njegovom trenutnom stanju. Ugradnjom ARMA filtra (Auto Regressive Moving Average) prije aktivacijske funkcije neurona, omogućuje se da dinamički neuron reagira na temelju trenutnih ulaznih signala, kao i na prethodno izračunate izlazne vrijednosti dinamičkog elementa tog neurona [15]. Osim osnovnih modela značajni su oni za specifične primjene kao što su:



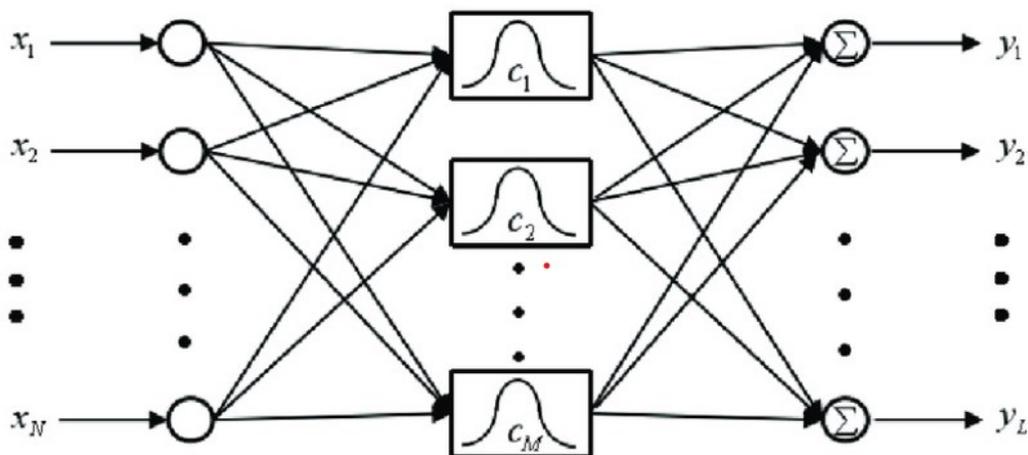
Slika 12. Konvolucijska neuronska mreža [17]

Konvolucijska neuronska mreža ili CNN je specijalizirana umjetna mreža dizajnirana za obradu slika, pri čemu koristi konvolucijske slojeve za automatsko učenje hijerarhijskih karakteristika iz ulaznih slika, omogućujući učinkovito prepoznavanje i klasifikaciju slika. Primjena konvolucijske neuronske mreže omogućila je revoluciju u području računalnog vida, gdje rješava ključne zadatke poput prepoznavanja objekata i analize slika [13].



Slika 13. Rekurentna neuronska mreža [18]

Rekurentna neuronska mreža je vrsta neuronske mreže namijenjena za obradu sekvencijalnih podataka, zbog čega je pogodna za primjene gdje su kontekstualne ovisnosti ključne, poput predviđanja vremenskih serija i obrade prirodnog jezika, jer koristi povratne veze koje omogućuju zadržavanje informacija unutar mreže. Štoviše, također je značajna vrsta rekurentne neuronske mreže s dugoročno kratkoročnom koja je dizajnirana za rješavanje problema nestajanja gradijenta pri treniranju rekurentne mreže, pri čemu koristi memorijske ćelije i vrata za selektivno čitanje, pisanje i brisanje informacija [13].



Slika 14. RBF neuronska mreža [16]

Radikalna bazna funkcijska (RBF) mreža razlikuju se od drugih neuronskih mreža jer ulazni sloj ne izvodi nikakve proračune. Umjesto toga, prosljeđuje podatke izravno skrivenom sloju. Kao rezultat toga, RBF mreže imaju bržu brzinu učenja. Primjene RBF mreža uključuju predviđanje vremenskih serija i aproksimaciju funkcija [13].

4.4. Prednosti i nedostaci neuronskih mreža

Kompleksni modeli umjetne inteligencije koji predstavlja neuronska mreža se koriste u različitim područjima zbog svojih brojnih prednosti. Ključna je njihova sposobnost prilagodbe u novim situacijama i učenje iz podataka, što ih čini izuzetno korisnima u zadacima prepoznavanja obrazaca, kao što su prepoznavanje govora i slike te obrada prirodnog jezika. Također, zahvaljujući paralelnoj obradi, neuronske mreže omogućuju brže i učinkovitije izračune, dok nelinearnost aktivacijskih funkcija omogućuju modeliranje složenih odnosa u podacima, što nadilazi ograničenja linearnih modela.

Ipak, neuronske mreže imaju i svoje nedostatke. Treniranje velikih mreža može biti računalno zahtjevno, zahtijevajući velike količine memorije. Njihova "black box" priroda, koja otežava razumijevanje procesa donošenja odluka, može predstavljati problem u ključnim primjenama. Također, mreže su sklone prenaučivosti, kada umjesto prepoznavanja obrazaca memoriraju podatke iz treninga, a učinkovitost im često ovisi o velikim, označenim skupovima podataka [13].

5. IZRADA MODELA NEURONSKE MREŽE ZA PREDVIĐANJE EFIKASNOSTI HIDRAULIČKU PUMPU

Za modeliranje neuronske mreže potrebno je pronaći odgovarajuće kataloške podatke za seriju pumpe koja se sastoji od većeg broja modela koji se razlikuju dimenzijama i radnim performansima. Velika količina podataka je značajna za što bolje treniranje i testiranje modela, u tu svrhu su preuzeti podatci iz [4]. Model neuronske mreže kao i prikazani grafovi su prikazani pomoću programskog paketa MATLAB.

5.1. Kataloški podaci

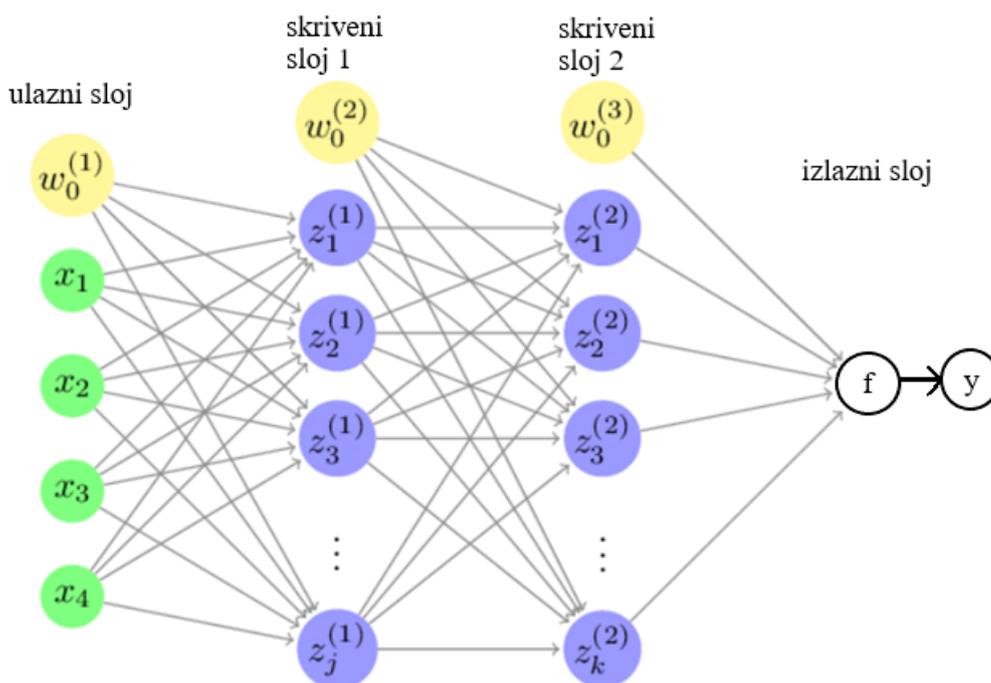
Odabrana je zupčasta hidraulička pumpa H-serije s vanjskim ozubljenjem proizvođača „Parker Hannifin“ koji je globalni lider u tehnologijama za pretvorbu gibanja i kontrole. Dizajnirane su s različitim tipovima brtvi kako bi minimizirale gubitke curenja. Jednostavne su, učinkovite, te sadrže mali broj pokretnih dijelova, što ih čini kompaktnima i laganima u odnosu na kapacitet koji pružaju. Njihova konstrukcija je idealna za rad pri visokim tlakovima i otporna na kavitaciju, s visokom tolerancijom na nečistoće te pouzdanim radom i u hladnim uvjetima. Imaju povoljan omjer snage i mase, što ih čini prikladnima za mobilnu hidrauliku. Međutim, karakterizira ih veća buka i volumetrički gubici, što smanjuje ukupni stupanj učinkovitosti ($\eta=75-90\%$). Štoviše, katalog sadrži podatke samo na specifičnim graničnim vrijednostima tlaka, protoka i brzine, a opisuje različite "familije" pumpi, među kojima je odabrana srednja "familija" s oznakom "H". Ova "familija" obuhvaća 7 podtipova pumpi, koji se razlikuju po volumenu, snazi i radnom području [4].

Tablica 1. Vrijednosti [4]

Oznaka pumpe	Volumen [cm^3]	Max. tlak [bar]	Max. snaga [kW]
H25	9,88	172	10,50
H31	12,36	172	13,26
H39	15,44	172	16,42
H49	19,30	172	20,65
H62	24,14	172	23,20
H77	30,18	138	23,30
H90	36,49	103	20,88

5.2. Struktura neuronske mreže za predviđanje efikasnosti

Kod modeliranja neuronske mreže koristi se model duboke neuronske mreže koji se sastoji od četiri ulazna čvora, dva skrivena sloja i jednog izlaza, pri čemu se koristi povratna propagacija s funkcijom gubitaka poznatom kao MSE, a za optimizaciju mreže primijenjena je L2 regularizacija.



Slika 15. Prikaz osnovne strukture neuronske mreže [19]

Ulaz mreže predstavljen s jediničnim neuronom i četiri neurona koja opisuju osnovne veličine hidrauličke pumpe, a to su : tlak, protok, brzina i istiskljivost. Skriveni slojevi sastoji se od BIAS-a te broja neurona koji varira s obzirom na potrebe modela. Za aktivaciju neurona koristi se funkcija tangens hiperbolni koja omogućuje mreži učenje složenih uzoraka i relacija između podataka. Izlazni neuron predstavlja efikasnost hidrauličke pumpe kao jedne od najvažnijih značajki. Srednje kvadratna greška u povratnoj propagacije omogućuje prilagođavanje težina mreže zajedno s L2 regularizacijom.

L2 ili Ridge regularizacija dodaje kaznu koja je proporcionalna kvadratu težine modela, a opisan je formulom:

$$\lambda * \sum_i W_i^2 \quad (7)$$

gdje je λ regularizacijski parametar, a W_i su težine modela. Regularizacijski parametar potiče model na manje težine, čime model postaje manje složen i osjetljiv na fluktuacije u podacima, čime se povećava njegova sposobnost generalizacije te smanjuje sklonost prekomjernom prilagođavanju [20].

5.3. Pristup i analizi zadatka

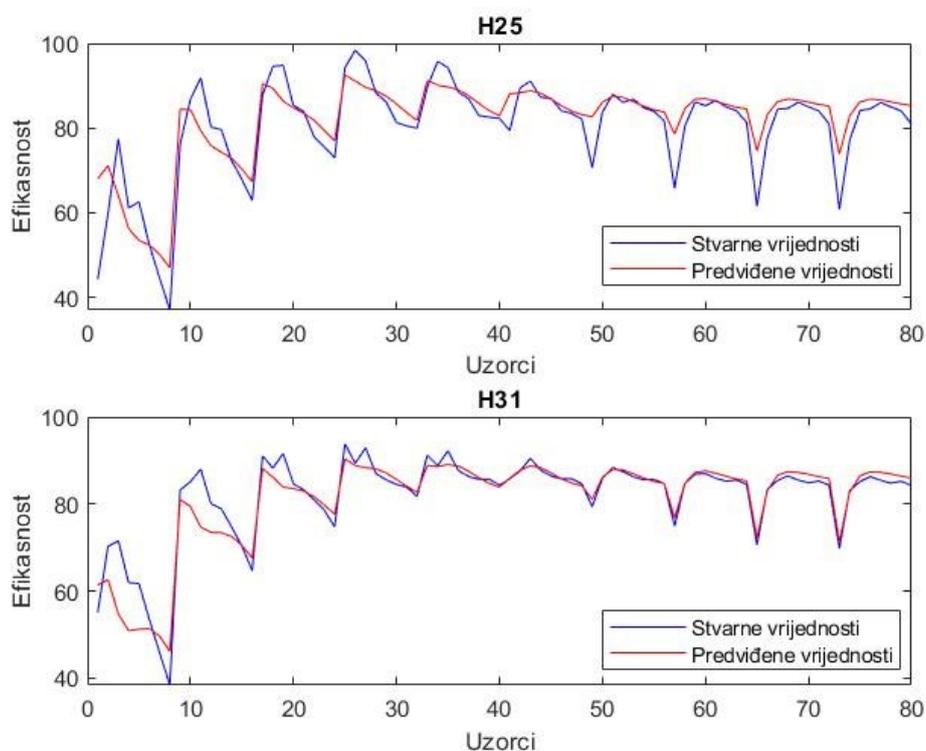
S obzirom da efikasnost hidrauličkog sustava ovisi o dimenzijama njegovih komponenti, stoga se kod optimalnog dimenzioniranja hidrauličkog sustava koriste modeli koji vjerno opisuju gubitke za širok raspon veličina komponenata. Prema tome podaci preuzeti iz kataloga, normalizirani, te podijeljeni prema dimenzijskim karakteristikama kako bi shvatili koji je najbolji pristup za opisivanje gubitaka hidrauličke pumpe. Setovi za treniranje podijeljeni su u specifične kategorije tako da se model trenira na pet modela iz serije, dok se na dva modela provodi predviđanje. Kod je napravljen u programskom paketu MATLAB uz primjenu više for petlji kroz koje se model prilagođava i daje najbolje rezultate. Važno je napomenuti da su for petlje korištene tako da se proizvode modeli neuronske mreže s različitim koeficijentima učenja, strukturama skrivenih slojeva, te iteracije pri učenju pri čemu su za usporedbu rezultata koristi srednja kvadratna greška, te se sprema za onaj model koji postiže najmanju vrijednost. Ovaj pristup za određivanje strukture modela je korišten da se omogući modelu da nauči složene nelinearne odnose između ulaznih varijabli i izlazne varijable, te uz iterativnu analizu osigurava postizanje najboljih težina neuronske mreže, što pomaže bržoj i efikasnijoj konvergenciji modela tokom treniranja.

6. REZULTATI ANALIZE

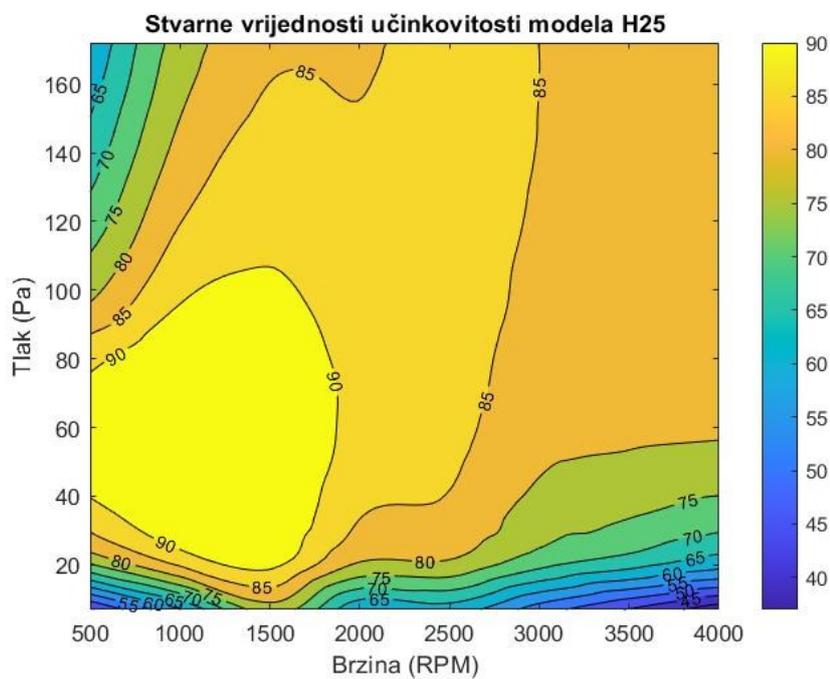
Rezultati su prikazani kao predviđanja na različitim modelima neuronske mreže koji su stvoreni na osnovu veličina dimenzijski specifičnih hidrauličkih pumpa. Grafički prikazi sadrže mape efikasnosti sa stvarnim i predviđenim vrijednostima, te razliku tih grafova kako bi istaknuli greške u radnim područjima. Osim toga značajan je graf NRMS za evaluaciju performansi modela kod predviđanja, a posebno je koristan za usporedbu grešaka između različitih skupova podataka. Utjecaj broja neurona na efikasnost modela također je prikazana u svrhu analize strukture.

6.1. Predviđanja na modelima H25 i H31

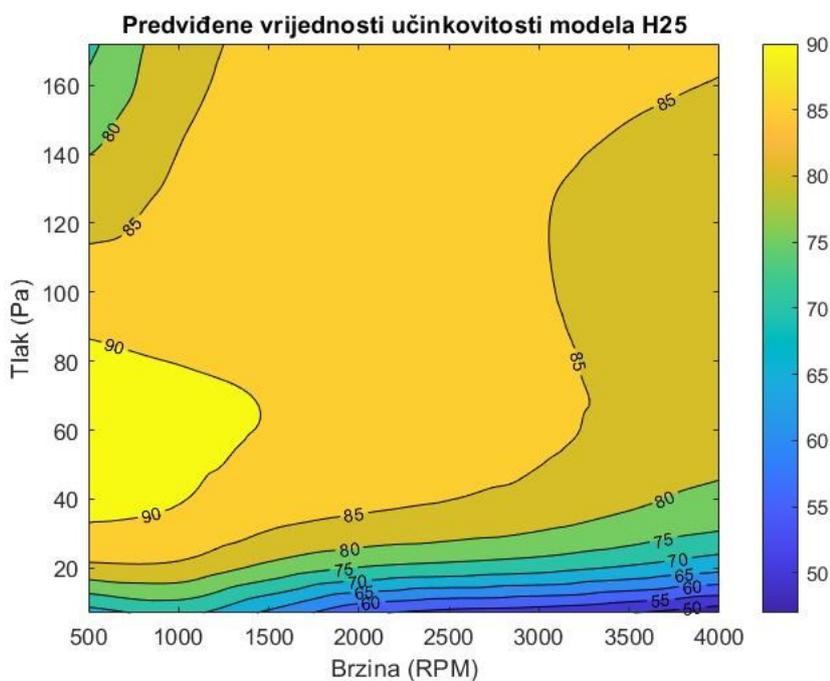
Nakon treniranja izrađen je model koji je najbolji za predviđanje efikasnosti pumpa H25 i H31 a sastoji se od dva skrivena sloja po 12 neurona, koeficijentom učenja koji iznosi 0,003 i brojem iteracija od 8500, također je važno napomenuti da koeficijent regularizacije lambda iznosi 0,001. Najbolji MSE u ovom slučaju za model H25 iznosi 33,46, dok za model H31 iznosi 14,81.



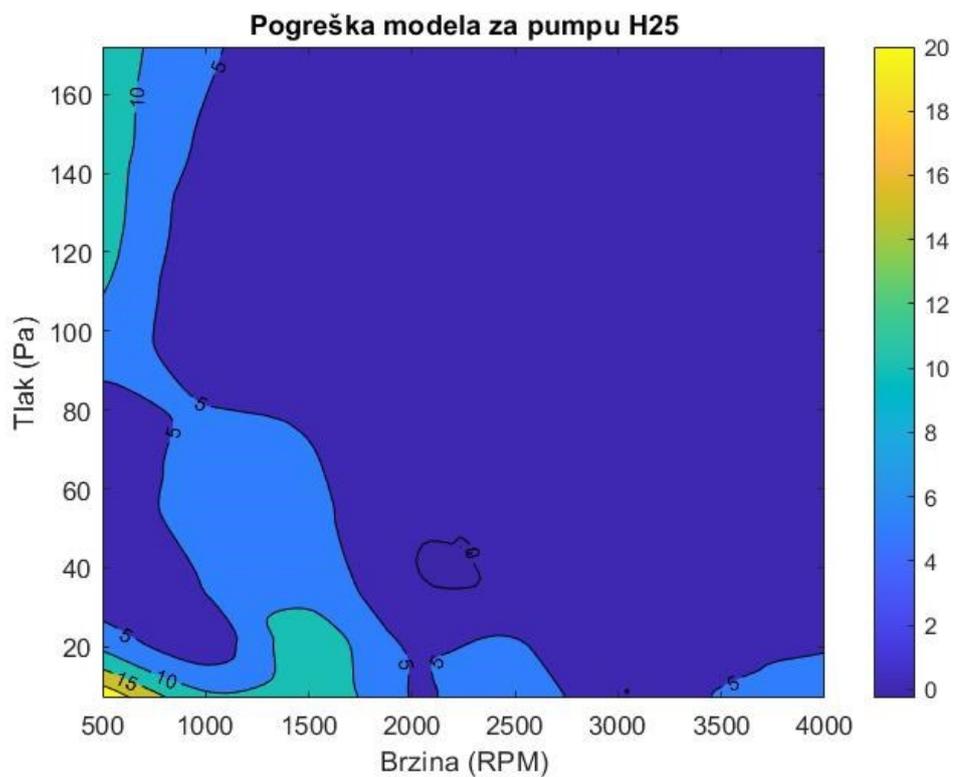
Slika 16. Usporedba stvarnih i predviđenih vrijednosti modela



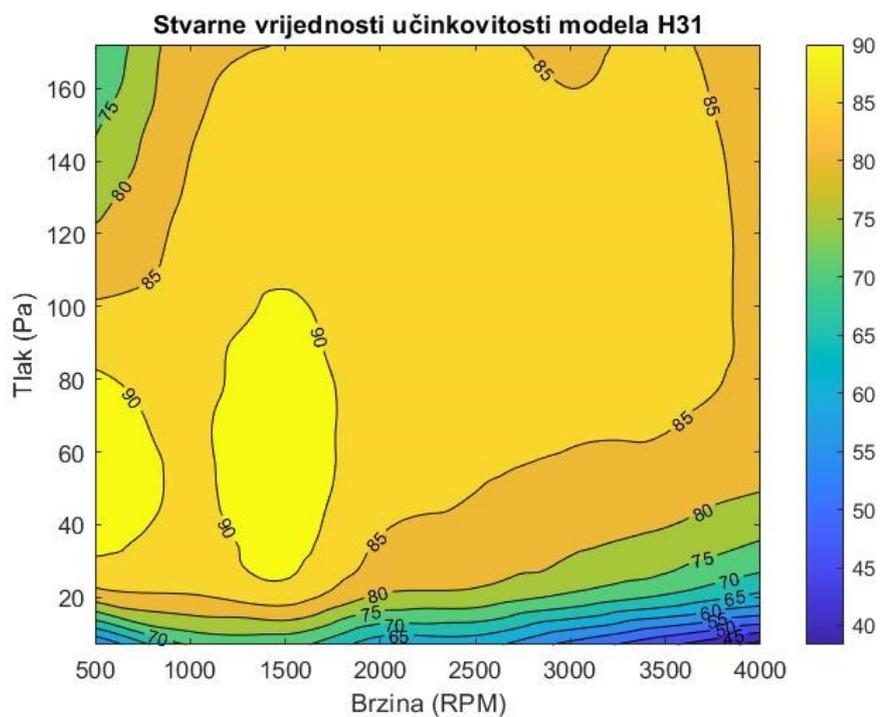
Slika 17. Mapa učinkovitosti pumpe H25



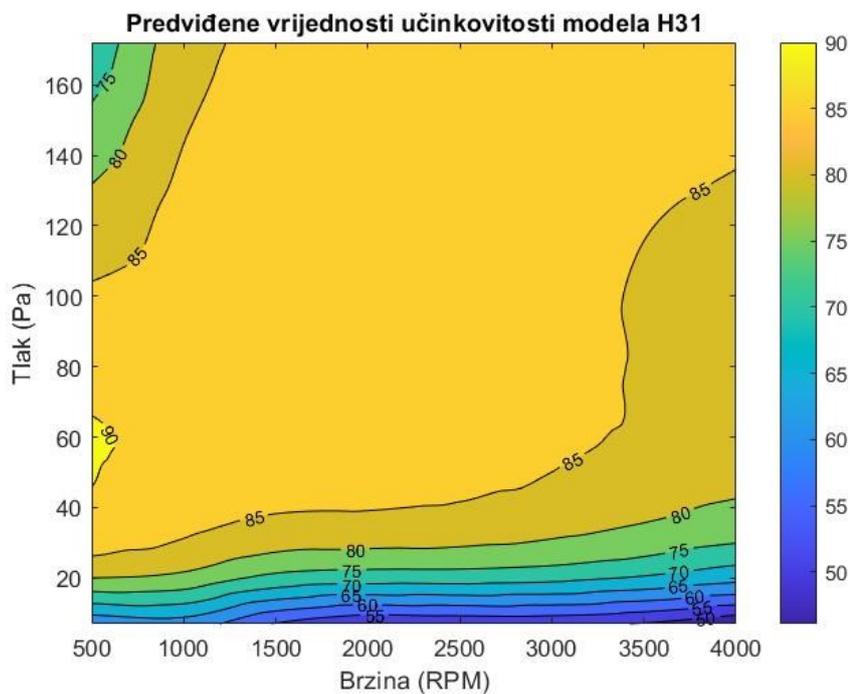
Slika 18. Predviđena mapa učinkovitosti za pumpu H25



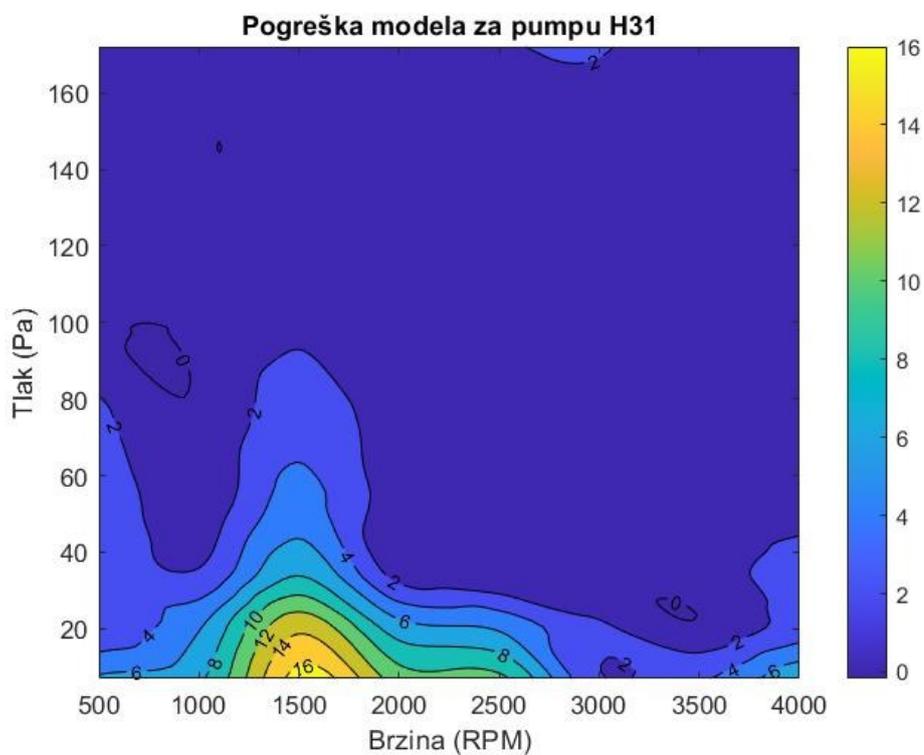
Slika 19. Pogreška modela za pumpu H25



Slika 20. Mapa učinkovitosti pumpe H31

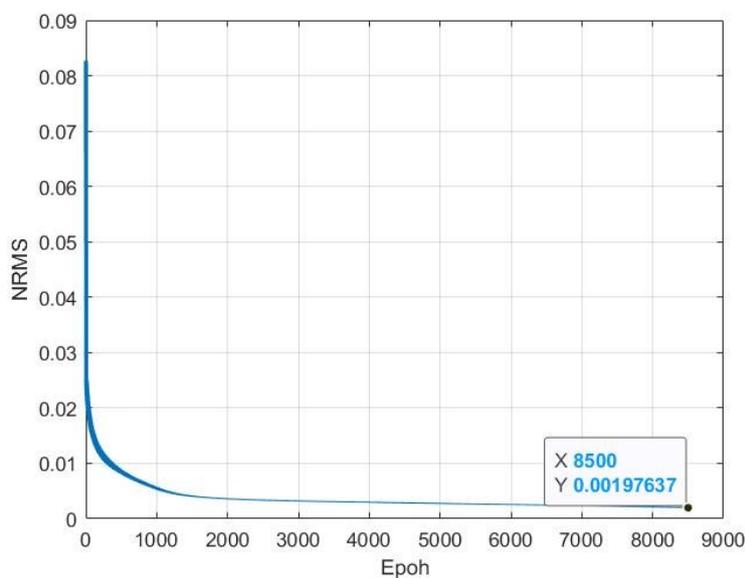


Slika 21. Predviđena mapa učinkovitosti za pumpu H31



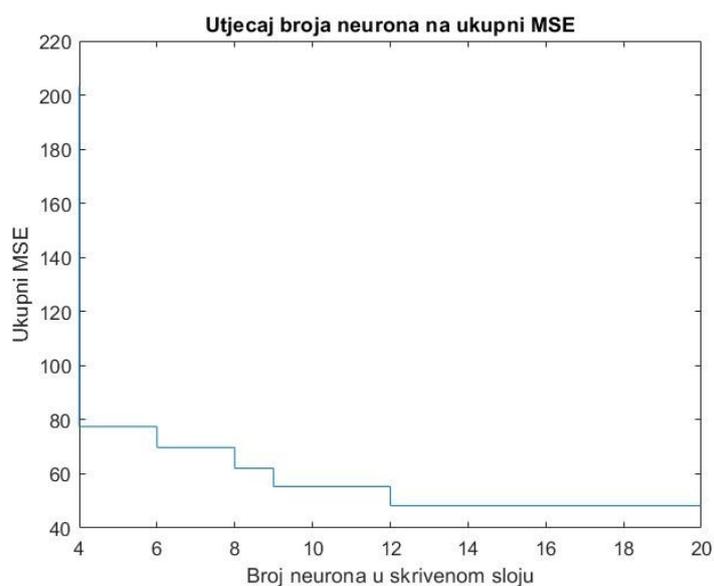
Slika 22. Pogreška modela za pumpu H31

Najveće greške kod modela H25 i H31 javljaju se u području niskog tlaka, te pri manjim brzinama, dok pri visokim tlakovima i brzinama model H25 ima manja odstupanja, dok model H31 puno bolje opisuje to područje.



Slika 23. NRMS za model neuronske mreže br.1

Iz NRMS grafa se vidi da model nikad ne predviđa stvarne vrijednosti savršeno nego je najmanja greška između stvarne i predviđene vrijednosti 0,002.

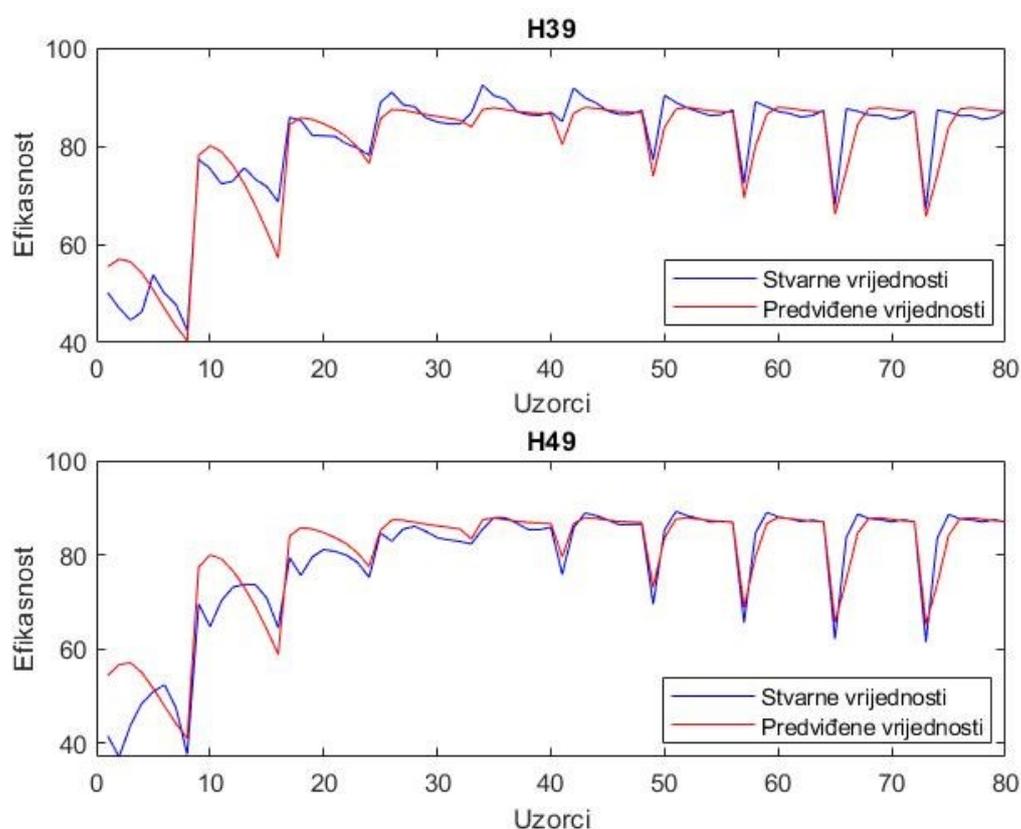


Slika 24. Utjecaj broja neurona na ukupni MSE

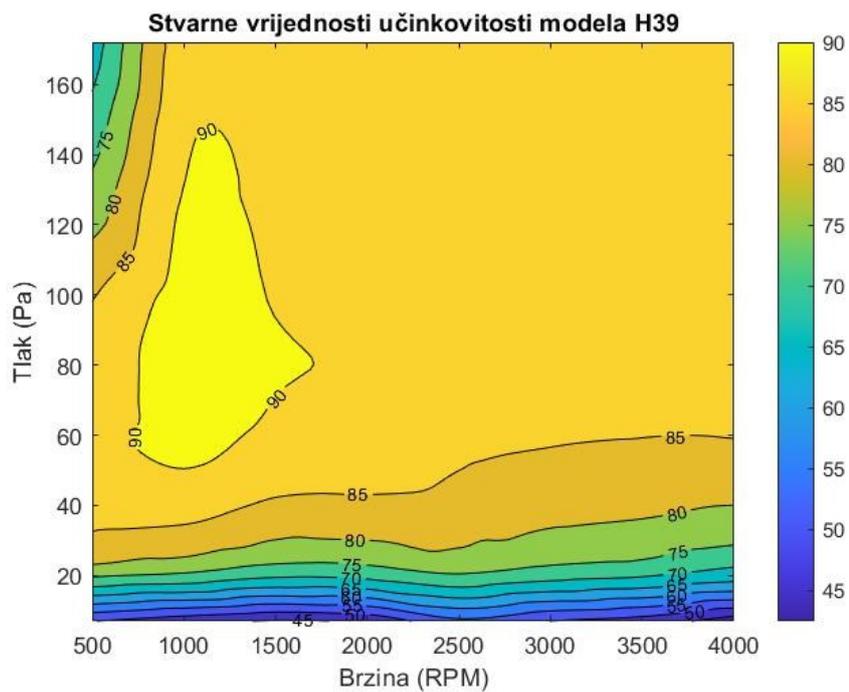
Nakon strukture od 12 neurona povećavanje broja neurona gubi smisao jer nema utjecaja na ukupni MSE pri predviđanju.

6.2. Predviđanja na modelima H39 i H49

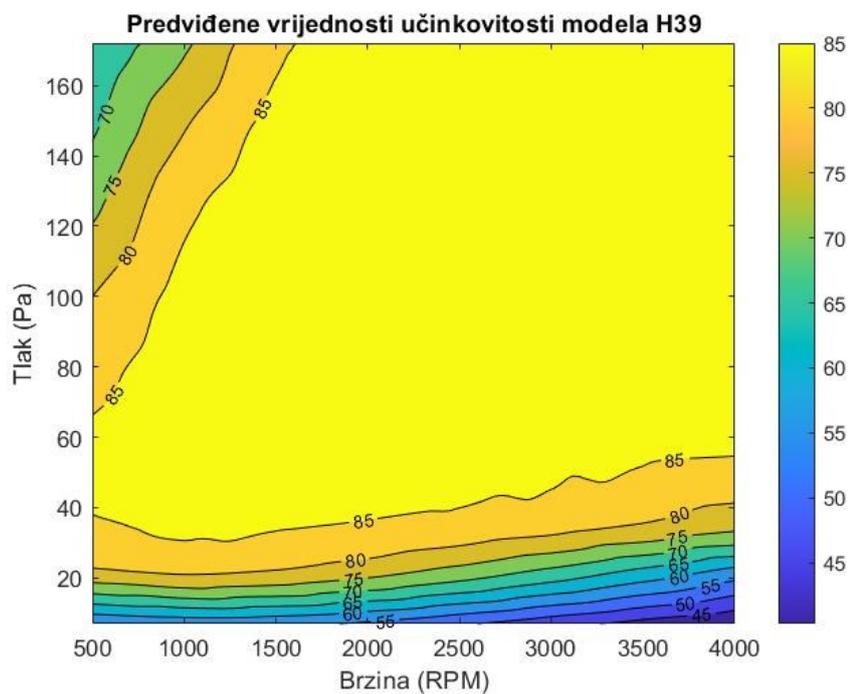
Model koji je najbolji za predviđanje efikasnosti pumpa H39 i H49 a sastoji se od dva skrivena sloja po 4 neurona , koeficijentom učenja koji iznosi 0,01 i brojem iteracija od 3500 uz koeficijent regularizacije lambda iznosi 0,001. Najbolji MSE u ovom slučaju za model H39 iznosi 17,37, dok za model H49 iznosi 23,38.



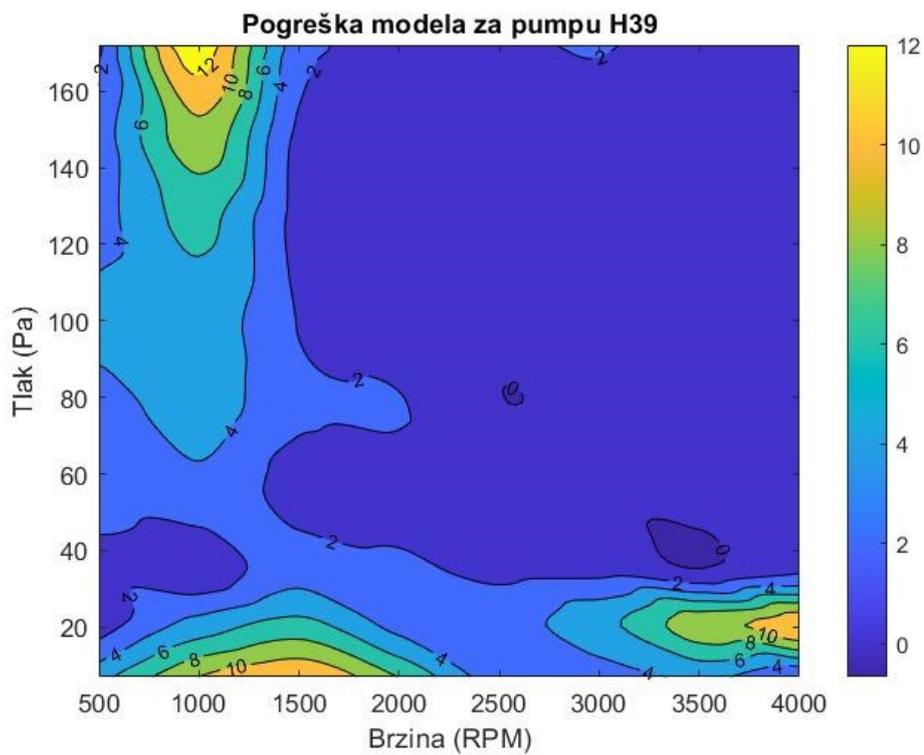
Slika 25. Usporedba stvarnih i predviđenih vrijednosti modela



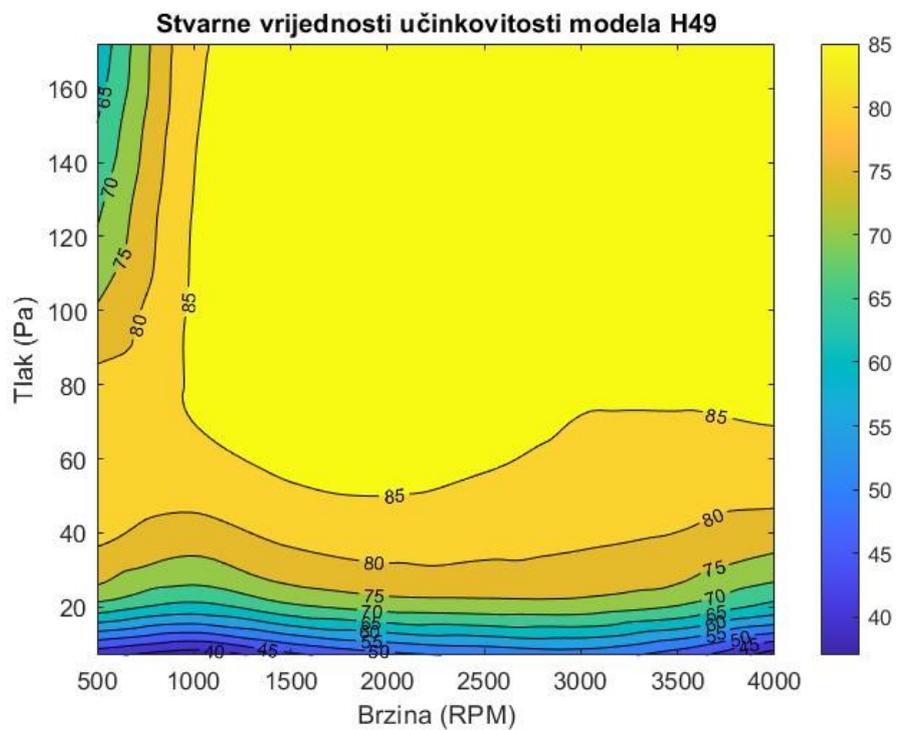
Slika 26. Mapa učinkovitosti pumpe H39



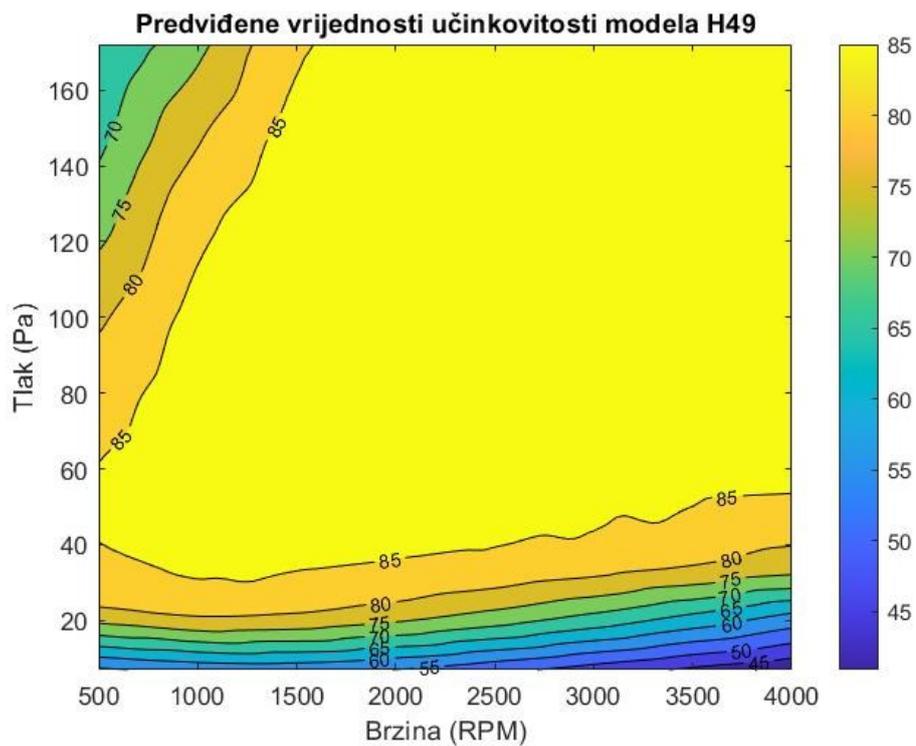
Slika 27. Predviđena mapa učinkovitosti za pumpu H31



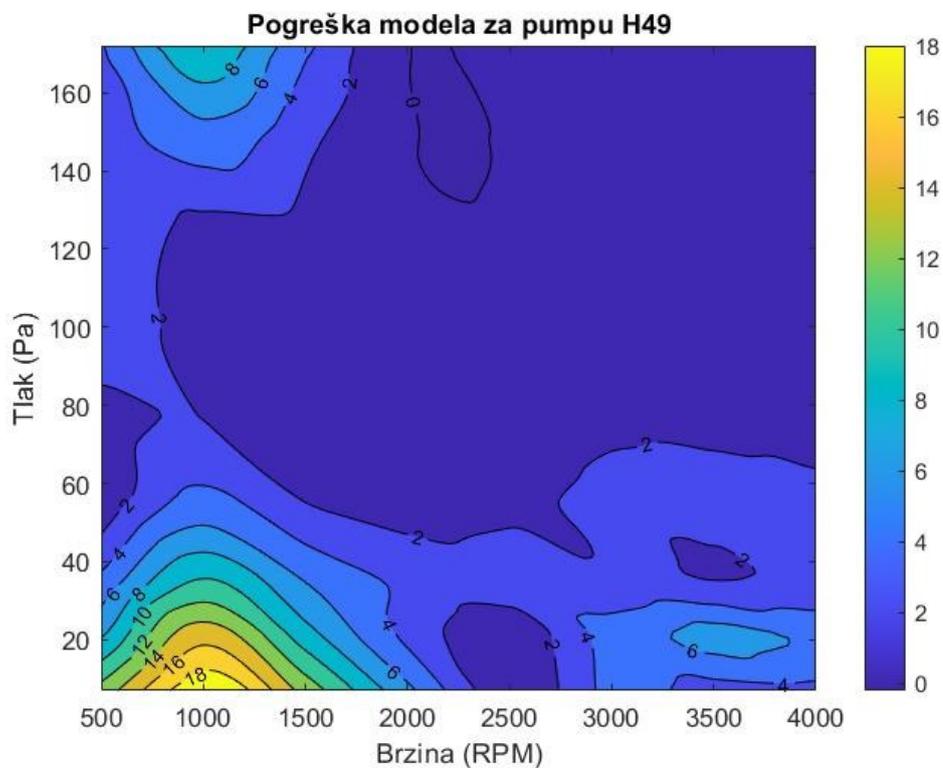
Slika 28. Pogreška modela za pumpu H39



Slika 29. Mapa učinkovitosti pumpe H49

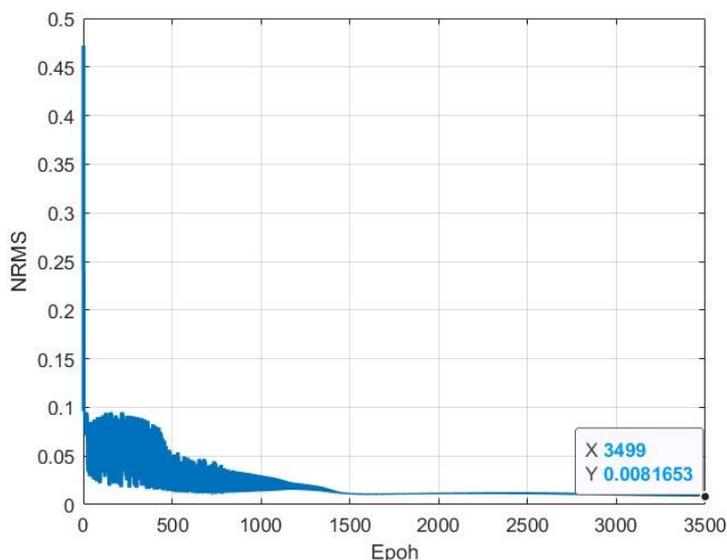


Slika 30. Predviđena mapa učinkovitosti za pumpu H49



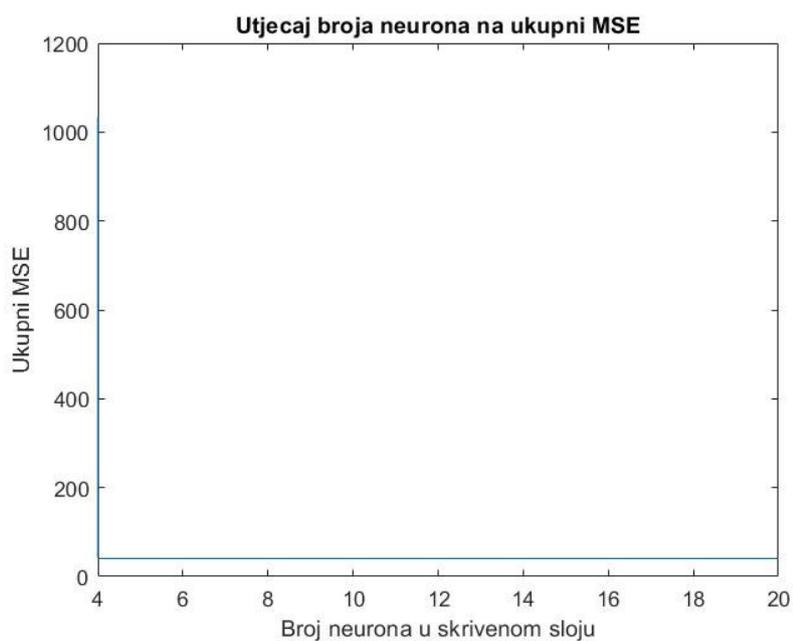
Slika 31. Pogreška modela za pumpu H39

Najveće greške kod modela H39 i H49 javljaju se u području niskog tlaka, te pri manjim brzinama. Veće greške također su značajne za visoke tlakove pri manjim brzinama, dok su minimalne greške karakteristične za područje visokog tlaka, pri većim brzinama.



Slika 32. NRMS za model neuronske mreže br.2

Iz NRMS grafa se vidi da model nikad ne predviđa stvarne vrijednosti savršeno nego je najmanja greška između stvarne i predviđene vrijednosti 0,0082.

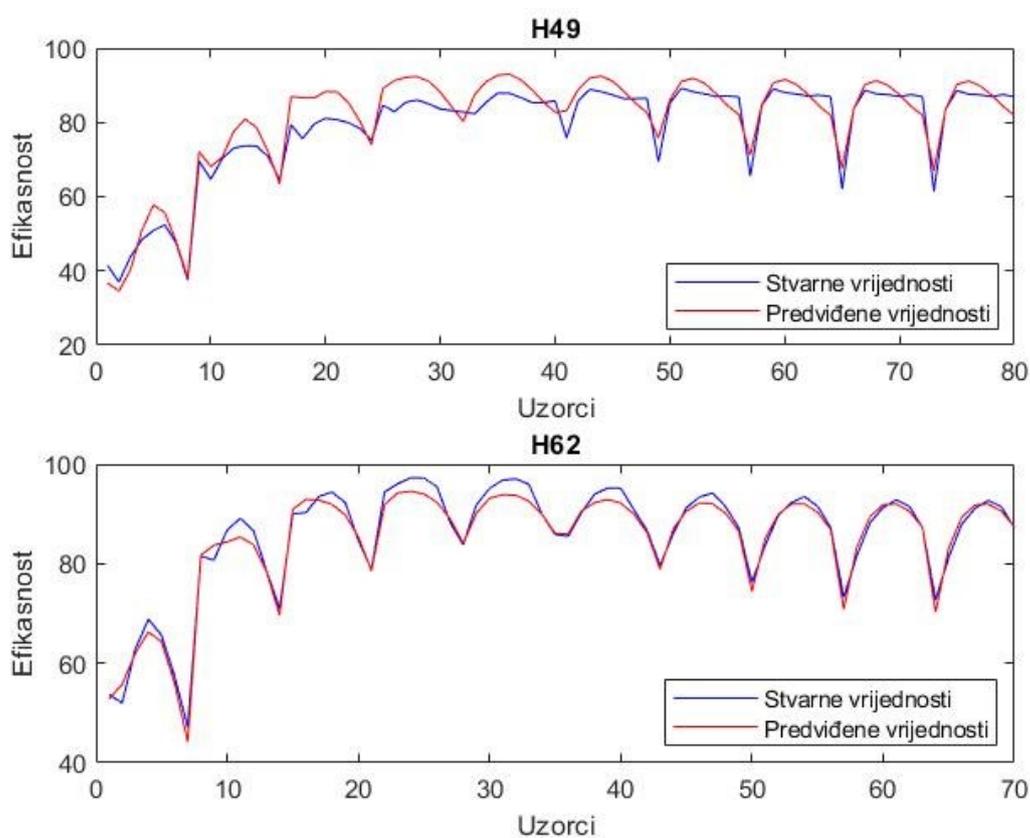


Slika 33. Utjecaj broja neurona na ukupni MSE

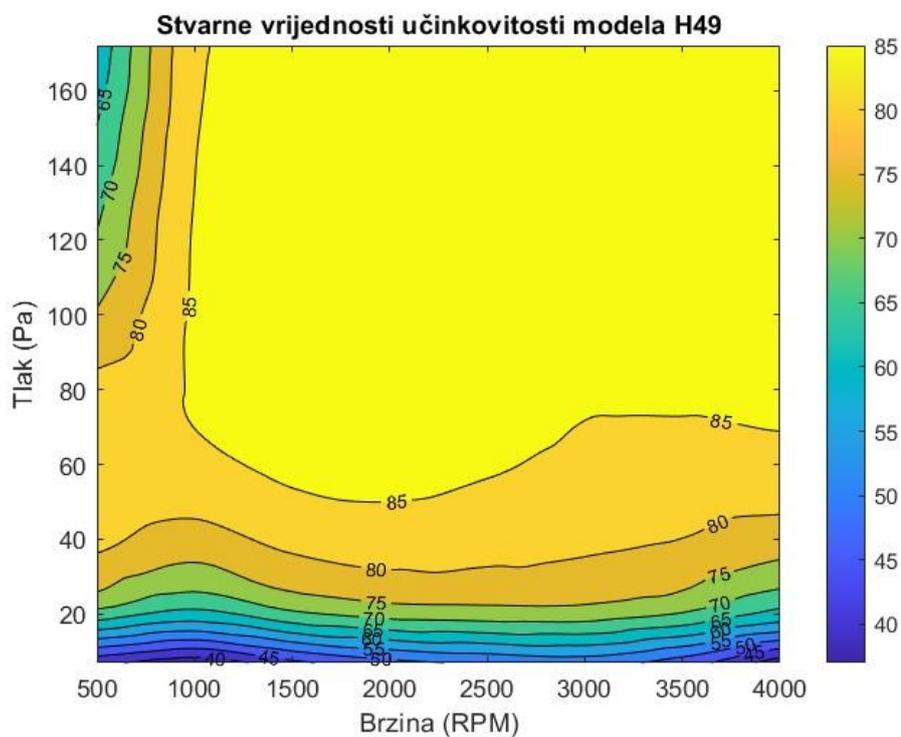
Nakon strukture od 4 neurona povećavanje broja neurona gubi smisao jer nema značajnih razlika na ukupni MSE kod predviđanja.

6.3. Predviđanja na modelima H49 i H62

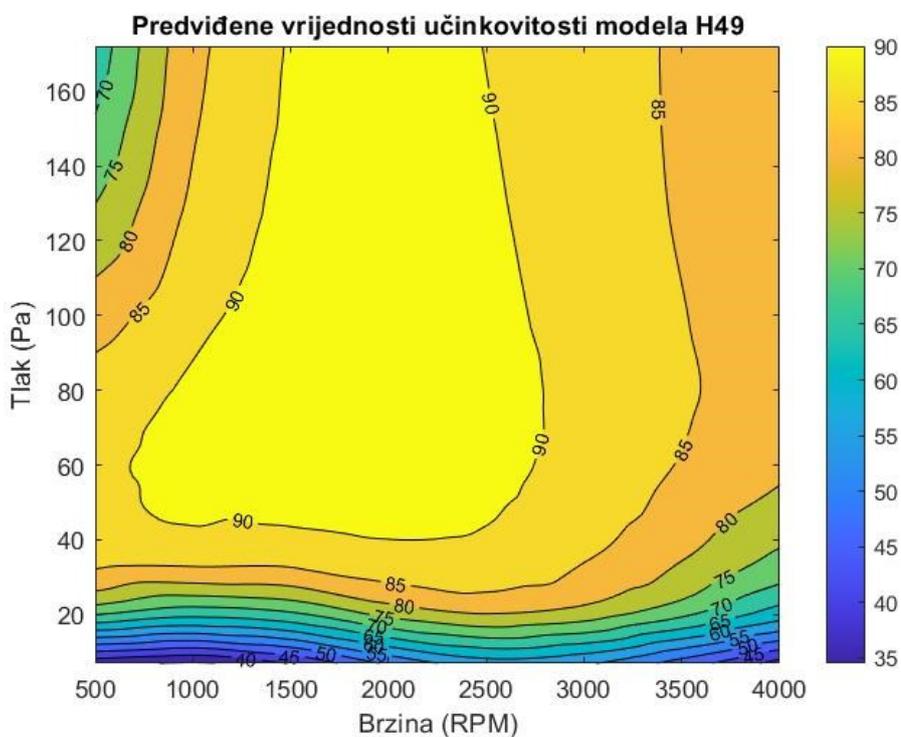
Struktura modela koji je najbolji za predviđanje efikasnosti pumpa H49 i H62 a sastoji se od dva skrivena sloja po 19 neurona, koeficijentom učenja koji iznosi 0,008 i brojem iteracija od 8500, također je važno napomenuti da koeficijent regularizacije lambda iznosi 0,001. Najbolji MSE u ovom slučaju za model H49 iznosi 18,4, dok za model H62 iznosi 3,32.



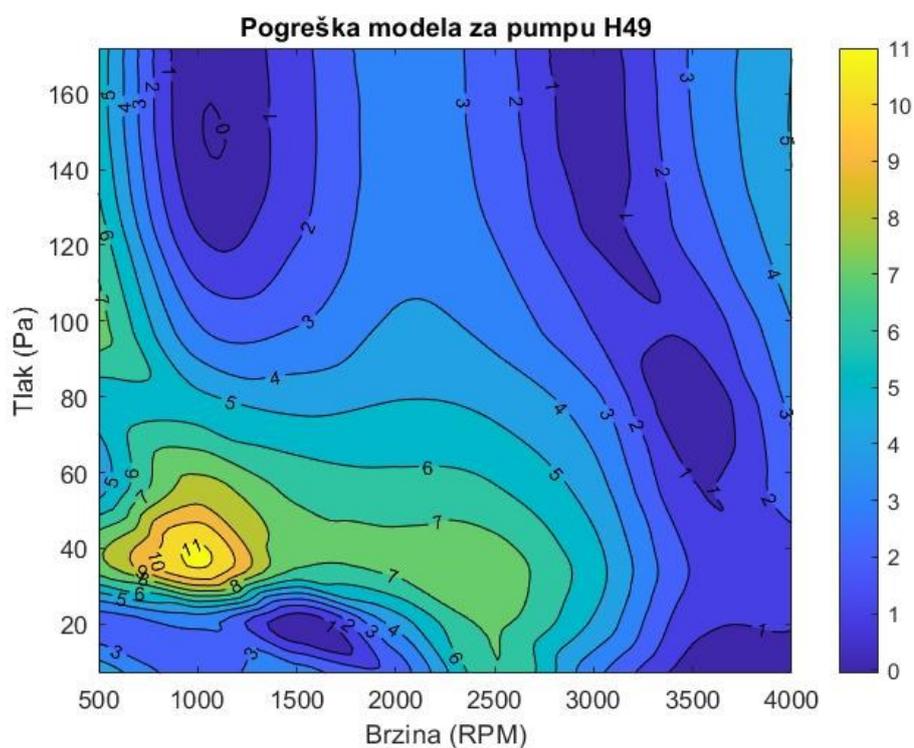
Slika 34. Usporedba stvarnih i predviđenih vrijednosti modela



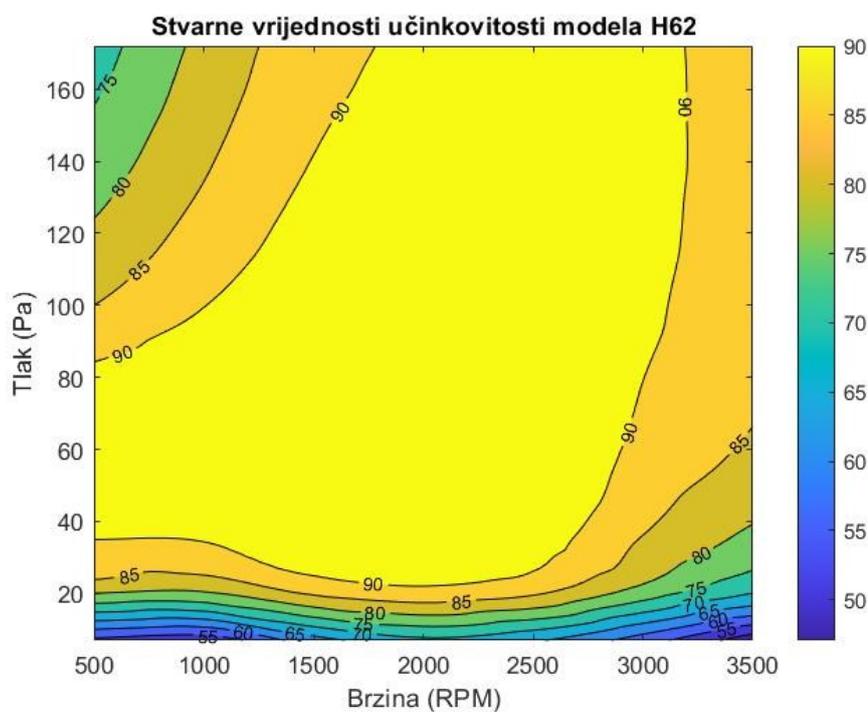
Slika 35. Mapa učinkovitosti pumpe H49



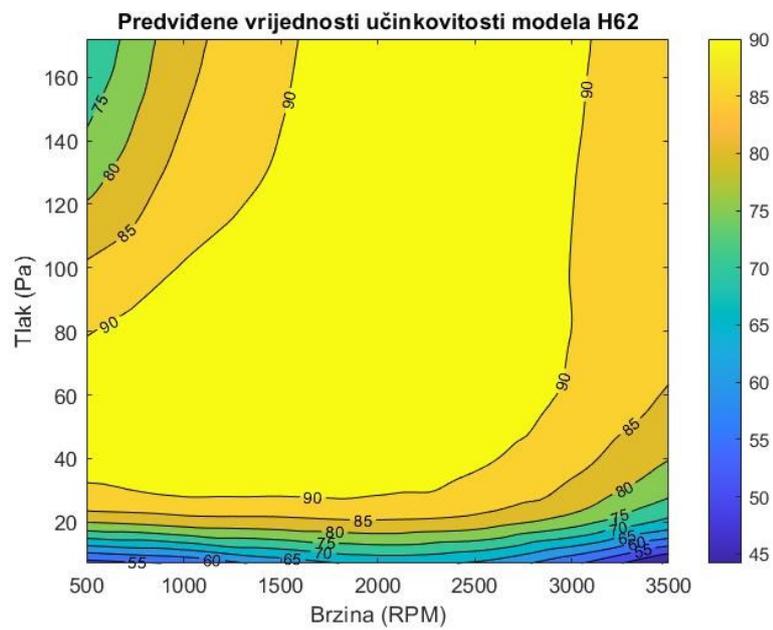
Slika 36. Predviđena mapa učinkovitosti za pumpu H49



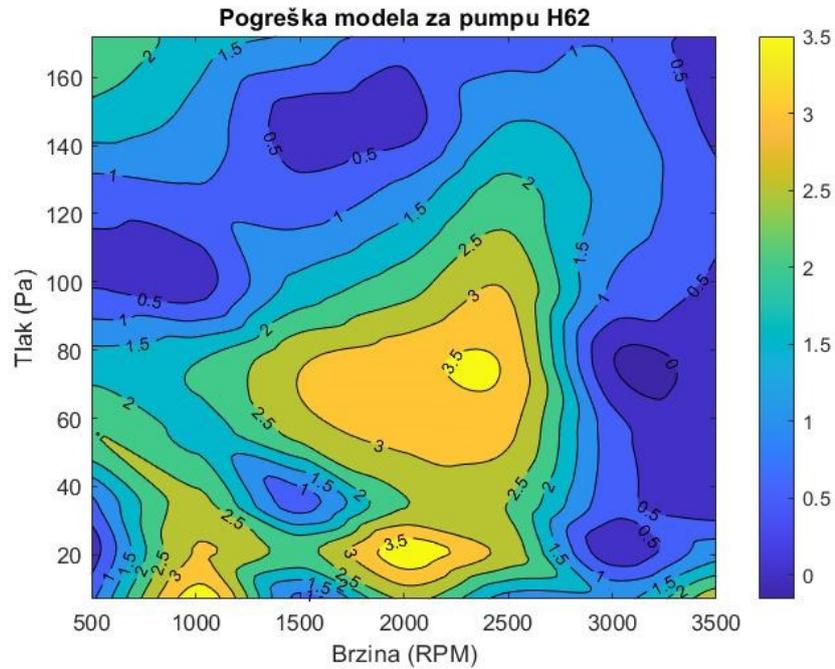
Slika 37. Pogreška modela za pumpu H39



Slika 38. Mapa učinkovitosti pumpe H62

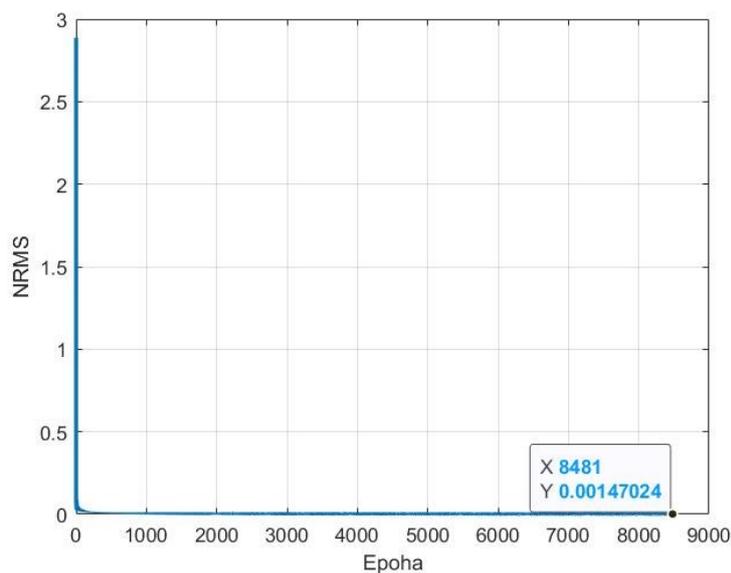


Slika 39. Predviđena mapa učinkovitosti za pumpu H62



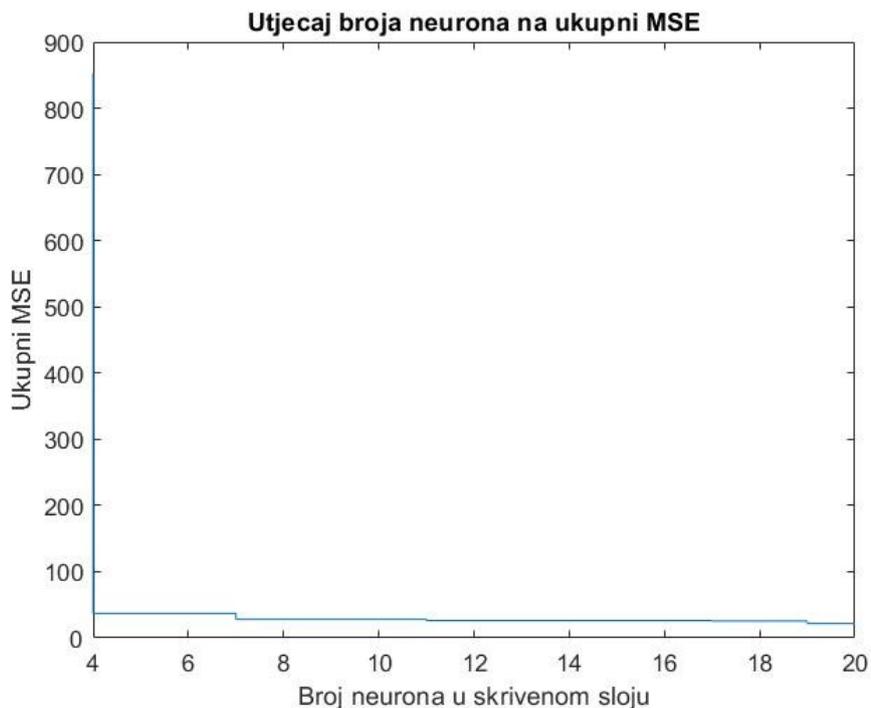
Slika 40. Pogreška modela za pumpu H62

Kod modela H49 i H62 greške se javljaju podjednako u radnom području, ali za razliku od prethodnih modela one su puno manje i ravnomjerno su raspoređene.



Slika 41. NRMS za model neuronske mreže br.3

Iz NRMS grafa se vidi da model nikad ne predviđa stvarne vrijednosti savršeno nego je najmanja greška između stvarne i predviđene vrijednosti 0,0015.

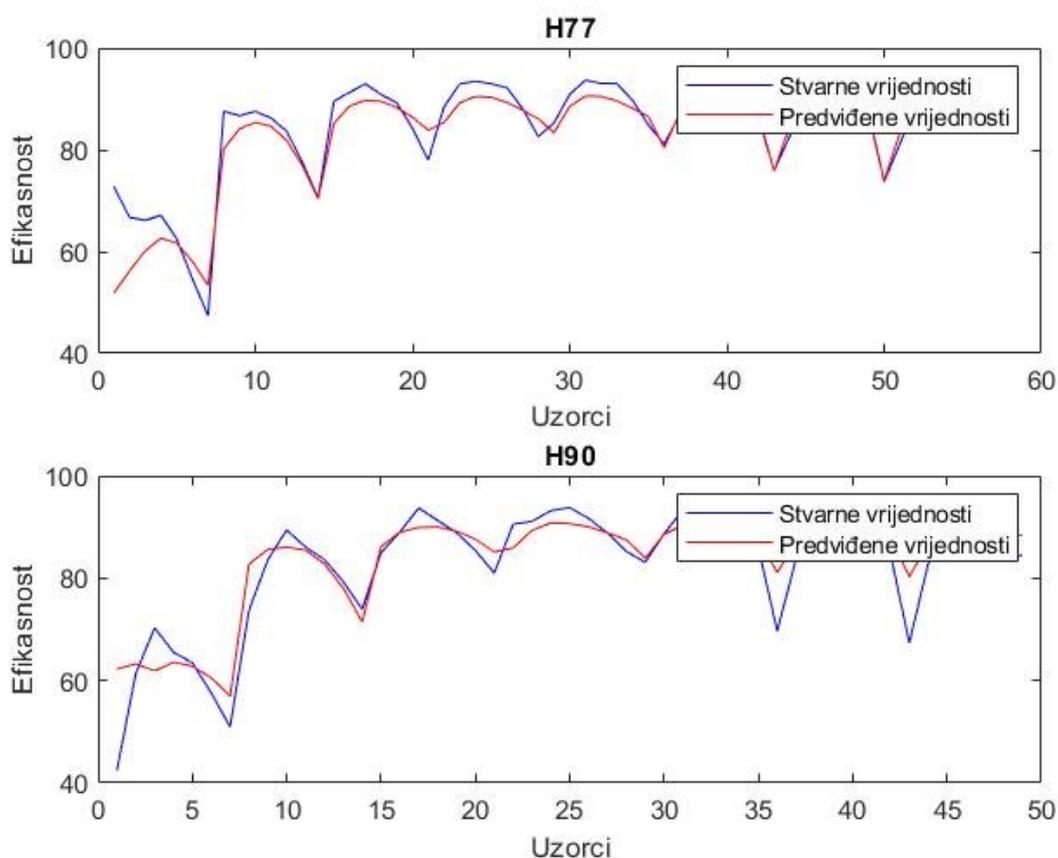


Slika 42. Utjecaj broja neurona na ukupni MSE

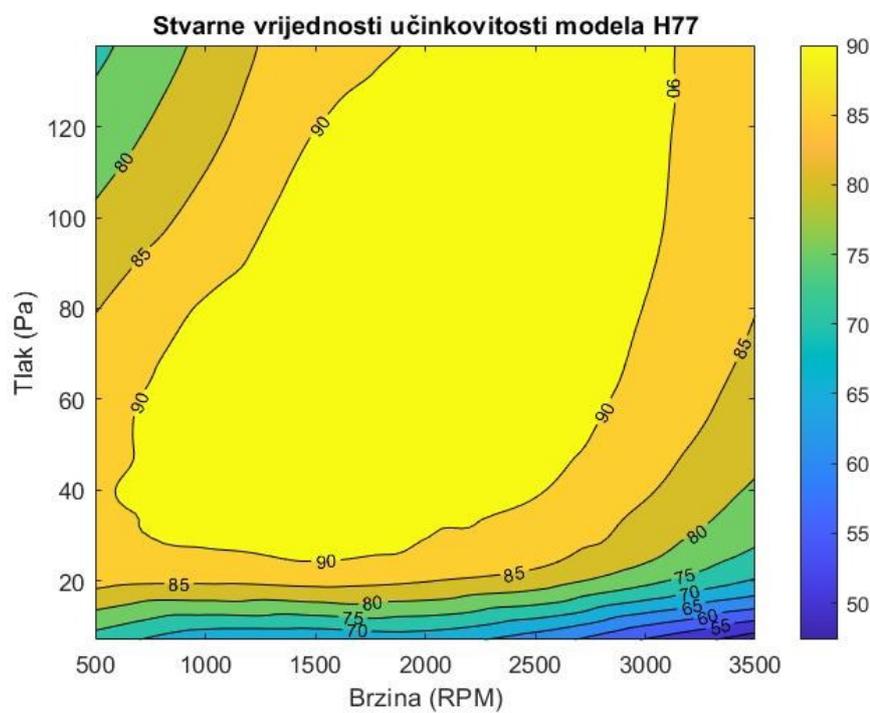
Nakon strukture od 19 neurona povećavanje broja neurona gubi smisao jer nema značajnih razlika na ukupni MSE kod predviđanja.

6.4. Predviđanja na modelima H77 i H90

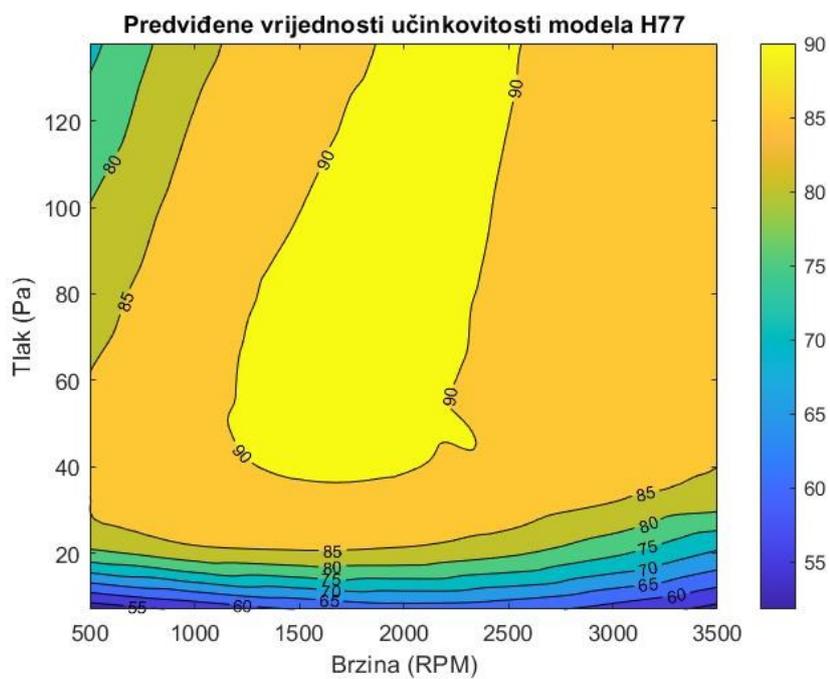
Modela neuronske mrže koji je najbolji za predviđanje efikasnosti pumpa H77 i H90 a sastoji se od dva skrivena sloja po 4 neurona, koeficijentom učenja koji iznosi 0,009 i brojem iteracija od 8000, također je važno napomenuti da koeficijent regularizacije lambda iznosi 0,001. Najbolji MSE u ovom slučaju za model H77 iznosi 17,07, dok za model H90 iznosi 24,60.



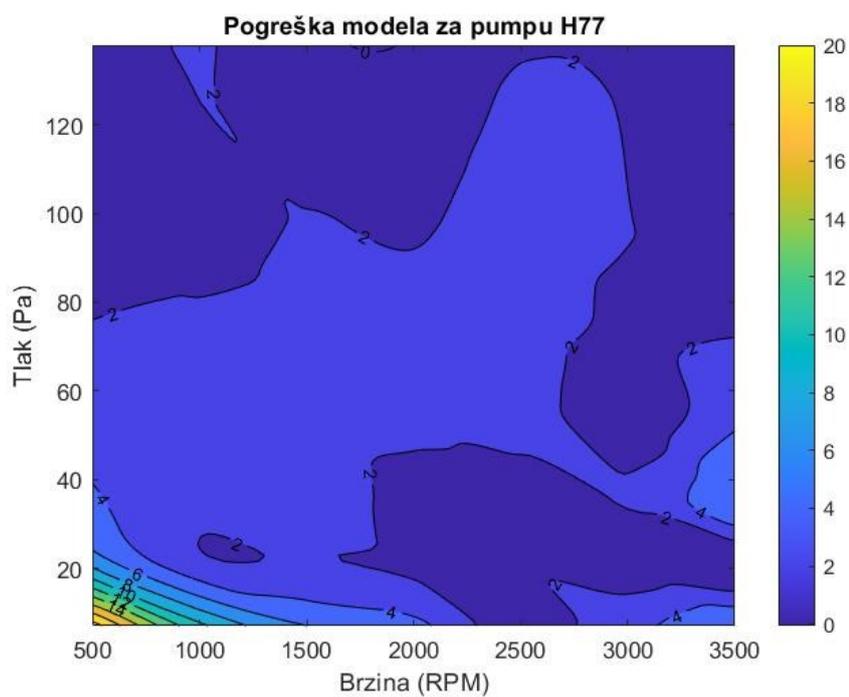
Slika 43. Usporedba stvarnih i predviđenih vrijednosti modela



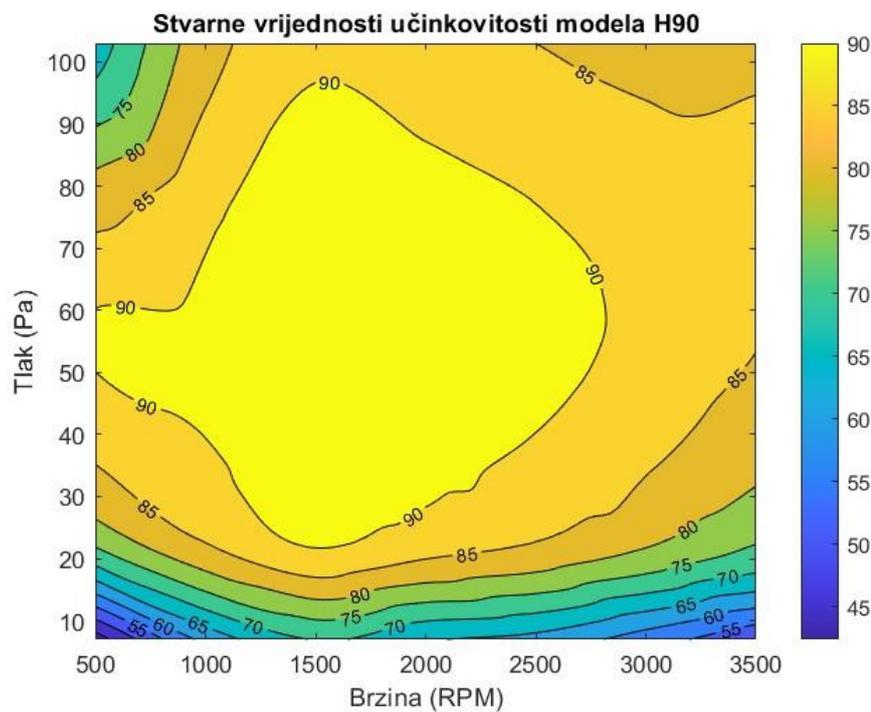
Slika 44. Mapa učinkovitosti pumpe H77



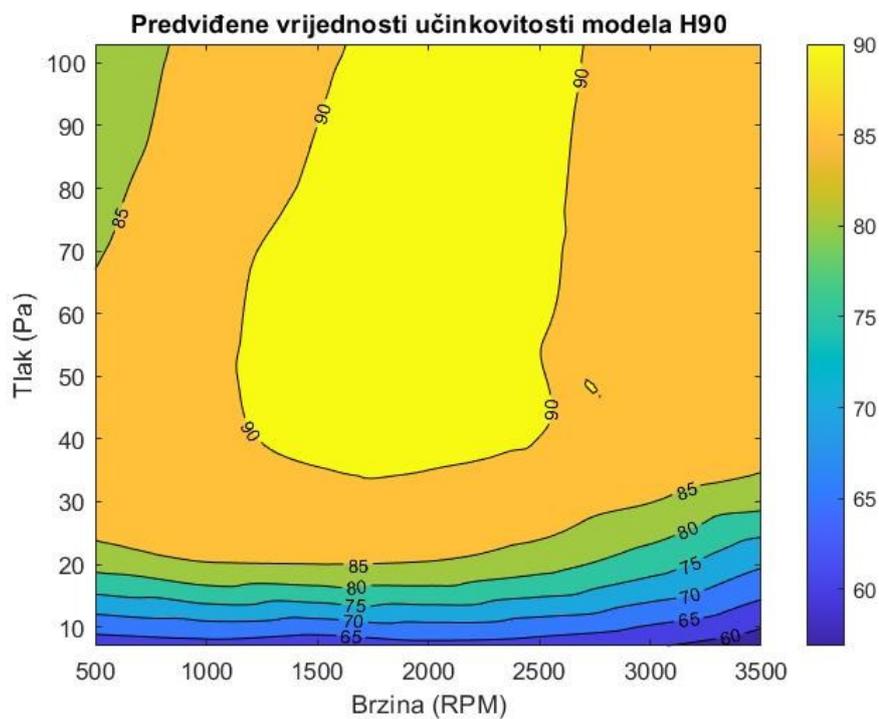
Slika 45. Predviđena mapa učinkovitosti za pumpu H77



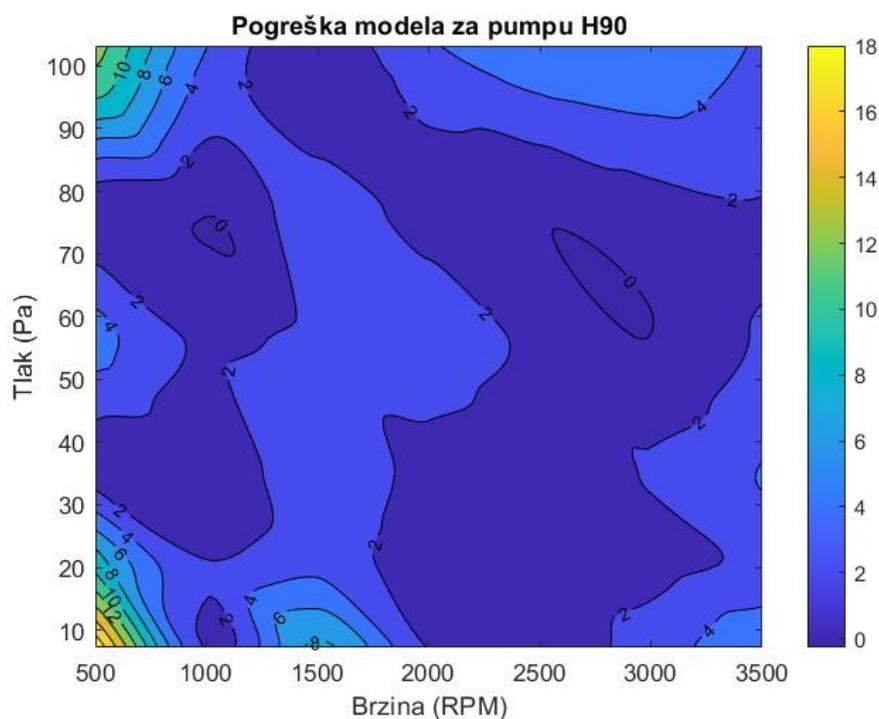
Slika 46. Pogreška modela za pumpu H77



Slika 47. Mapa učinkovitosti pumpe H90

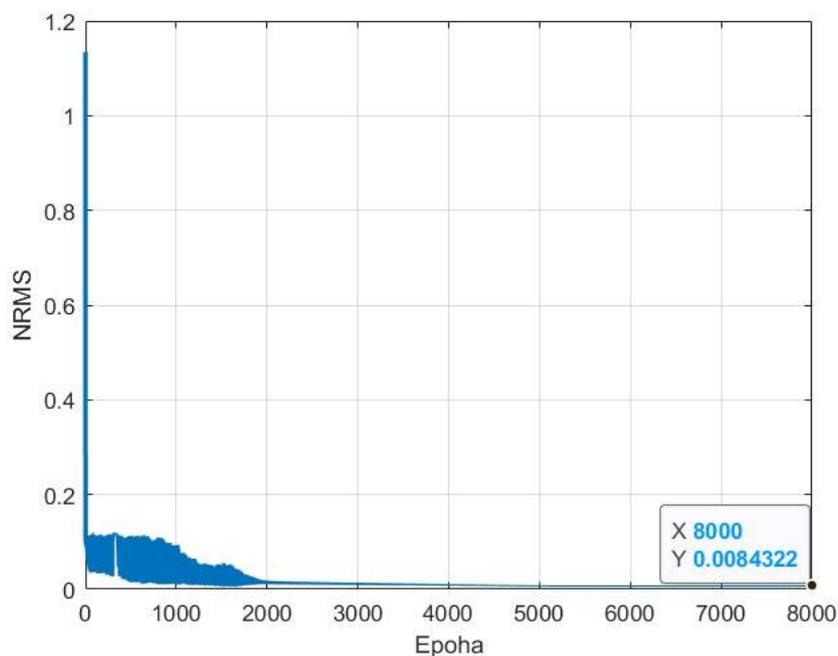


Slika 48. Predviđena mapa učinkovitosti za pumpu H90



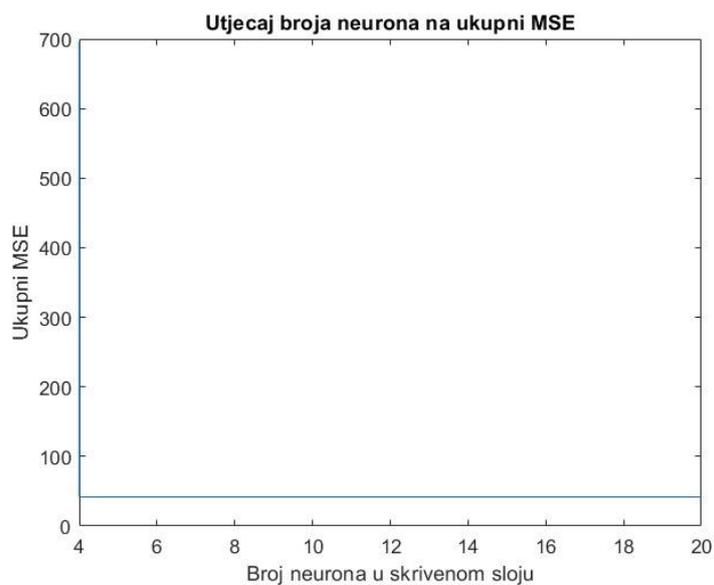
Slika 49. Pogreška modela za pumpu H77

Za model H77 najveće greške su u području niskog tlaka pri manjim brzinama dok se kod pumpe H90 odstupanja javljaju i pri većim brzinama i tlakovima.



Slika 50. NRMS za model neuronske mreže br.4

Iz NRMS grafa se vidi da model nikad ne predviđa stvarne vrijednosti savršeno nego je najmanja greška između stvarne i predviđene vrijednosti 0,0084.



Slika 51. Utjecaj broja neurona na ukupni MSE

Nakon strukture od 4 neurona povećavanje broja neurona gubi smisao jer nema značajnih razlika

6.5. Diskusija

U ovom poglavlju predstavljeni su rezultati četiriju različitih modela neuronske mreže koji su korišteni za predikciju učinkovitosti zupčaste hidrauličke pumpe. Analiza uključuje usporedbu modela prema njihovoj točnosti, brzini konvergencije te otpornosti na varijacije u ulaznim podacima. Kroz ovu diskusiju razmatra se i skalabilnost svakog modela, odnosno njihova sposobnost prilagodbe na veće skupove podataka ili složenije sustave bez gubitka performansi.

S obzirom da je svaki model treniran na različitom setu podataka razvijena su četiri modela koja su testirana na dva modela hidrauličke pumpe, pri čemu se svaki razlikuje u strukturi, točnosti i brzini konvergencije, što rezultira različitim prilagodbom modela. Tablica broj 2 prikazuje srednju kvadratnu grešku za svaki model na kojem je mreža trenirana.

Tablica 2. Greška modela neuronske mreže

Model neuronske mreže	MSE-1	MSE-2
1	33,46	14,81
2	17,37	23,38
3	18,40	3,32
4	17,07	24,60

Iz tablice se vidi da se srednje kvadratne greške svakog modela neuronske mreže razlikuju, pri čemu ni jedan model ne pokazuje znakove skalabilnosti s obzirom na veliku razliku između srednjih kvadratnih grešaka testiranih modela hidrauličke pumpe. S tim rečeno za svaku seriju pumpe potrebno je posebno treniranje, ali s obzirom na provedeno istraživanje vidi se da je moguće dobiti dosta dobro predviđanje modela koji su trenirani na najvećim i najmanjim modelima iz serije hidrauličke pumpe iz čega se vidi da je moguće stvoriti modeli neuronske mreže koji bi bio treniran na dimenzijski većim i manjim pumpama u svrhu smanjenja srednje kvadratne greške međudimenziskih modela pumpe, ali ne znači da bi modeli s takvim pristupom bio skalabilan za širi spektar dimenzija hidrauličke pumpe.

7. ZAKLJUČAK

Predviđanje efikasnosti hidrauličkih pumpi predstavlja važan korak prema optimizaciji hidrauličkih sustava, smanjenju operativnih troškova i povećanju pouzdanosti industrijskih procesa. U ovom radu, istražena je primjena neuronskih mreža kao naprednog alata za modeliranje složenih odnosa između različitih parametara koji utječu na učinkovitost rada hidrauličkih pumpi. Kroz implementaciju i testiranje više arhitektura neuronskih mreža, pokazalo se da ove mreže mogu predvidjeti efikasnost pumpi u određenom području rada.

Rezultati pokazuju da neuronske mreže uspijevaju u određenom spektru predvidjeti efikasnost pumpe s obzirom na podatke s kojima je trenirana. S obzirom na način treniranja mreže razlikuju se četiri karakteristična modela, od kojih najbolje rezultate daje model koji je treniran s podacima od manjih i većih modela pumpe, međutim ti su podaci raspršeni po cijelom radnom području, dok modeli trenirani samo na većim ili manjim modelima pumpe daju odlične rezultate u samo jednom radnom spektru. Ovim pristupom dolazimo do zaključka koji nam govori ako imamo dovoljno podataka koji opisuju veće i manje modele pumpi možemo dobiti modele neuronske mreže koji jako dobro opisuju karakteristike međudimenzijskih modela pumpe, međutim ovaj pristup ne daje skalabilni model, što govori da ovaj pristup s neuronskom mrežom nije uvelike adekvatan za predloženi problem.

U budućim istraživanjima, predlaže se daljnje usavršavanje modela putem integracije drugih tehnika strojnog učenja te proširenje skupa podataka kako bi se obuhvatile dodatne varijable i scenariji. Također, razvoj hibridnih modela koji kombiniraju neuronske mreže s fizičkim modelima hidrauličkih sustava mogao bi dodatno povećati točnost predviđanja. Sve u svemu, rezultati ovog rada ukazuju na značajan potencijal neuronskih mreža u industrijskim primjenama, pružajući čvrstu osnovu za daljnji razvoj i implementaciju u stvarnim sustavima.

LITERATURA

- [1] <https://www.whitehouseproductsltd.com/blog/what-are-hydraulic-pumps-used-for?aliaspath=%2fBlog%2fWhat-Are-Hydraulic-Pumps-Used-For>
- [2] Boruah, D.; Thakur, P.K.; Baruah, Dispal: *Artificial Neural Network based Modelling of Internal Combustion Engine Performance*, 2016.
- [3] https://hr.wikipedia.org/wiki/Hidrauli%C4%8Dka_pumpa
- [4] Kučinić, Damir: *Dimenzioniranje, modeliranje i simulacija servohidrauličke pumpe*, Zagreb, 2008.
- [5] <https://hr.hydraulic-pump-parts.com/info/useful-information-on-gear-pumps-77728570.html>
- [6] <https://www.powermotiontech.com/hydraulics/hydraulic-pumps-motors/article/21884136/engineering-essentials-fundamentals-of-hydraulic-pumps>
- [7] <https://www.hydraulic-calculation.com/article.php?ID=43>
- [8] Cipek, M.; Petrić, J.; Pavković, D.; Kučinić, D.: A Hydraulic Component Scalability Tool based on Willans Line Method towards the Optimal Design of Hybrid Hydraulic Vehicles,
- [9] https://www.roymech.co.uk/Related/Hydrostatics/Hydraulic_pumps.html
- [10] <https://www.sciencedirect.com/topics/engineering/black-box-model>
- [11] <https://www.cloudflare.com/learning/ai/what-is-neural-network/>
- [12] Heinert, M.: *Artificial neural networks – how to open the black boxes?*, 2008
- [13] <https://www.geeksforgeeks.org/neural-networks-a-beginners-guide/>
- [14] Turnar, R.: *Ubrzanje algoritama učenja neuronske mreže s povratnim rasprostranjem pogreške*, Zagreb, 2010
- [15] Kukurin, L.: *Predviđanje vremenskih serija primjenom umjetnih neuronskih mreža*, Zagreb, 2020
- [16] https://www.researchgate.net/figure/Structure-of-radial-basis-function-RBF-neural-network-in-N-M-L-form_fig1_346269515
- [17] Smolčić, Dario.: *Raspoznavanje objekata konvolucijskim neuronskim mrežama*, Zagreb, 2015
- [18] <https://www.scaler.com/topics/deep-learning/rnn/>
- [19] https://www.researchgate.net/figure/A-deep-neural-network-with-four-inputs-two-hidden-layers-and-one-output-The-numbers-of_fig1_371376078
- [20] Šnajder, J.: *Linearna regresija II*, Zagreb, 2022