



УНИВЕРЗИТЕТ „СВ. КИРИЛ И МЕТОДИЈ“ ВО СКОПЈЕ
МАШИНСКИ ФАКУЛТЕТ СКОПЈЕ



МАШИНСКИ
ФАКУЛТЕТ
СКОПЈЕ

Радмила Лазар Колева

**ПРИМЕНА НА ВЕШТАЧКА ИНТЕЛИГЕНЦИЈА И ДИГИТАЛЕН БЛИЗНАК ПРИ
ПРОЕКТИРАЊЕ И ИДЕНТИФИКАЦИЈА НА УПРАВУВАЧКИ СИСТЕМИ**

Докторски труд

Скопје, 2025



УНИВЕРЗИТЕТ „СВ. КИРИЛ И МЕТОДИЈ“ ВО СКОПЈЕ
МАШИНСКИ ФАКУЛТЕТ СКОПЈЕ



Радмила Лазар Колева

ПРИМЕНА НА ВЕШТАЧКА ИНТЕЛИГЕНЦИЈА И ДИГИТАЛЕН БЛИЗНАК ПРИ
ПРОЕКТИРАЊЕ И ИДЕНТИФИКАЦИЈА НА УПРАВУВАЧКИ СИСТЕМИ

Докторски труд

Скопје, 2025



УНИВЕРЗИТЕТ „СВ. КИРИЛ И МЕТОДИЈ“ ВО СКОПЈЕ
МАШИНСКИ ФАКУЛТЕТ СКОПЈЕ
Институ за Хидраулично инженерство и автоматика



Радмила Лазар Колева

**ARTIFICIAL INTELLIGENCE AND DIGITAL TWIN APPLICATION IN THE DESIGN AND
IDENTIFICATION OF CONTROL SYSTEMS**

**ПРИМЕНА НА ВЕШТАЧКА ИНТЕЛИГЕНЦИЈА И ДИГИТАЛЕН БЛИЗНАК ПРИ
ПРОЕКТИРАЊЕ И ИДЕНТИФИКАЦИЈА НА УПРАВУВАЧКИ СИСТЕМИ**

Докторски труд

Скопје, 2025



УНИВЕРЗИТЕТ „СВ. КИРИЛ И МЕТОДИЈ“ ВО СКОПЈЕ
МАШИНСКИ ФАКУЛТЕТ СКОПЈЕ
Институт за Хидраулично инженерство и автоматика



Радмила Лазар Колева

ARTIFICIAL INTELLIGENCE AND DIGITAL TWIN APPLICATION IN THE DESIGN AND
IDENTIFICATION OF CONTROL SYSTEMS

ПРИМЕНА НА ВЕШТАЧКА ИНТЕЛИГЕНЦИЈА И ДИГИТАЛЕН БЛИЗНАК ПРИ
ПРОЕКТИРАЊЕ И ИДЕНТИФИКАЦИЈА НА УПРАВУВАЧКИ СИСТЕМИ

Докторски труд

Скопје, 2025

Докторанд:
РАДМИЛА, ЛАЗАР КОЛЕВА

Тема:
ПРИМЕНА НА ВЕШТАЧКА ИНТЕЛИГЕНЦИЈА И ДИГИТАЛЕН БЛИЗНАК ПРИ
ПРОЕКТИРАЊЕ И ИДЕНТИФИКАЦИЈА НА УПРАВУВАЧКИ СИСТЕМИ

Ментор:

Проф. д-р ДАРКО БАБУНСКИ,
Машински факултет Скопје

Комисија за одбрана:

Проф. д-р ЛАЗЕ ТРАЈКОВСКИ (претседател)
Универзитет „Св. Кирил и Методиј“ во Скопје
Машински факултет Скопје

Проф. д-р ДАРКО БАБУНСКИ, ментор
Универзитет „Св. Кирил и Методиј“ во Скопје
Машински факултет Скопје

Проф. д-р АТАНАСКО ТУНЕСКИ, член
Универзитет „Св. Кирил и Методиј“ во Скопје
Машински факултет Скопје

Проф. д-р ЕМИЛ ЗАЕВ, член
Универзитет „Св. Кирил и Методиј“ во Скопје
Машински факултет Скопје

Проф. д-р ГЕРХАРД РАТХ, вонреден професор во пензија,
Катедра за автоматика и мерења,
Монтан Универзитет Леобен, Австрија

Научна област:

ТЕХНИЧКИ НАУКИ - МАШИНСТВО

Датум на одбрана:

26.09.2025

ПРИМЕНА НА ВЕШТАЧКА ИНТЕЛИГЕНЦИЈА И ДИГИТАЛЕН БЛИЗНАК ПРИ ПРОЕКТИРАЊЕ И ИДЕНТИФИКАЦИЈА НА УПРАВУВАЧКИ СИСТЕМИ

– А п с т р а к т –

Примената на напредни технологии како машинско учење (ML), вештачки невронски мрежи (ANN) и дигитален близнак (DT) во управувачките системи се почесто се присутни во процесот на револуционизирање на индустриите со цел подобрување на ефикасноста, адаптивноста и предвидливите способности. Овие технологии им овозможуваат на управувачките системи да учат од податоците, самостојно да се оптимизираат и да симулираат перформанси во реално време, правејќи го управувањето по pamетно и поприлагодливо на различни динамички услови. За таа цел во овој докторски труд, истражувањето се фокусира на интеграција на различни техники на ML со цел подобрување на ефикасноста и перформансите на управувачките системи пред се кај хидроенергетски објекти.

Целта на овој докторски труд е да се проучи можноста за користење на ANN, ML и DT преку науката за обработка на податочни множества. Истовремено, преку наведените техники да се развие специфична методологија за користење податочни множества, но и методологија за проектирање на пропорционално, интегрално и диференцијално (PID) управување. При тоа, дефинирањето на методологијата ќе доведе до можност за идентификација на систем за било кој управувачки систем со пречистено и реално податочно множество. При анализа на моделите, линеарните и нелинеарните карактеристики ќе зависат единствено од квалитетот и големината на обработуваното податочно множество. Користењето на податочните множества за создавање на DT ќе обезбедат основно разбирање на дејствувањето на системот, овозможувајќи попрецизни предвидувања и стратегии за идно управување и анализирање.

Методите на ML, што се земени во предвид при спроведување на истражувањето во овој докторски труд се мрежи со можност на задржување на старата, но важна информација подолг временски период – долга краткорочна меморија (LSTM) и методата на повеќеслоен перцептрон (MLP). Преку нив ќе се овозможи анализа на објектот на управување врз основа на анализа на претходни, историски податочни множества со цел подобрување на ефикасноста на системот преку негова соодветна идентификација, но и предвидување на константите на PID со помош на алгоритми на ANN за подобро управување.

Освен тоа, ќе биде прикажано и управување со директна примена на невронски мрежи (NN) во комбинација со закон за управување. Методата на брзопрототипирање (real-time control prototyping) ќе се искористи со цел да се анализираат и да се потврдат одзивите од смулациските модели преку кои ќе биде прикажано влијанието на параметрите добиени со помош на ML врз динамичките карактеристики на анализираните управувачки системи. Исто така од изведените лабораториски мерења ќе се покаже како поединечни параметри од NN влијаат при носење одлука за управување во реално време, но и тоа дека е потребен моќен процесор за обработка на големи податочни множества како би можел системот брзо да реагира на промени. Но исто така потребен е и современ процесор со цел обработка на моделот на ML при директна примена на хардвер.

Резултатите, но и прикажаните техники во овој докторски труд имаат потенцијал да го револуционизираат работењето и управувањето на управувачките системи, правејќи ги прилагодливи на променливи услови. Доколку како управувачки системи се разгледува еден хидроенергетски објект, овој докторски труд придонесува за размислување и овозможување кон постигнување почиста и поефикасна енергетска мрежа преку искористување на целосниот потенцијал на хидроенергетските ресурси. Тоа би можело да се постигне доколку во иднина хидроенергетските објекти бидат модернизирани со опрема за собирање и анализирање на податоци во реално време како би можело да се направи ефикасна анализа на измерените податоци и да се

направи управување со примена на методата на брзо прототипирање - real-time control prototyping во зависност од достапните и снимени податоци. Исто така преку овој докторски труд е направена анализа на параметрите од ANN, но и како тие влијаат врз управувањето на еден објект на управување.

Клучни зборови: објект на управување, машинско учење, LSTM, MLP, PID, предвидување, дигитален близнак, back-calculation, anti-windup

Благодарност

Најнапред, сакам да изразам искрена благодарност до сите кои на кој било начин придонесоа овој труд да биде успешно реализиран. Вашата поддршка, помош и охрабрување оставија неизбришлива трага во овој долг и значаен процес.

Посебно се заблагодарувам на мојот ментор, проф. д-р Дарко Бабунски, за неговата посветеност, стручност и трпение во насочувањето на мојата работа. Неговата поддршка и доверба беа клучни за завршувањето на овој докторат. Благодарност упатувам и до проф. д-р Емил Заев кој исто така со неговата посветеност, корисни совети и добронамерност помогна да квалитетот на овој докторски труд биде на повисоко ниво. Исто така им се заблагодарувам на проф. д-р Лазе Трајковски и д-р Атанаско Тунески кои значително придонесоа за квалитетот на овој труд.

Исклучителна благодарност упатувам до проф. д-р Герхард Ратх од Универзитетот во Леобен, Австрија, за неговата поддршка, менторство и укажаната можност да престојувам и работам на Катедрата за Автоматика при Универзитетот во Леобен, Австрија. Тој период беше непроценливо искуство кое многу придонесе за мојот истражувачки и личен развој.

Голема благодарност должам и на моето семејство — на татко ми Лазар, мајка ми Марица и сестра ми Магдалена — за нивната неизмерна љубов, охрабрување и трпение во текот на целиот процес. Без вашата поддршка овој пат би бил многу потежок.

Благодарност упатувам и до Гордана, за советите, разбирањето и истрајноста во сите моменти кога тоа ми беше најпотребно.

Најпосле, од срце му благодарам на Мартин, кој беше мој голем поттик во целиот овој предизвикувачки процес.

Изјавувам дека докторскиот труд е оригинален труд што го имам изработено самостојно.

Своерачен потпис на докторандот, с.р.
Радмила Колева

(на електронската верзија на докторски труд)

Изјавувам дека електронската верзија на докторскиот труд е идентична со отпечатениот докторски труд.

Потпис на авторот, с.р
Радмила Колева

СОДРЖИНА

Преглед на симболи поврзани со моделирање на хидроенергетски објект	xiv
Преглед на симболи поврзани со машинско учење.....	xv
Преглед на кратенки	xvi
Карактеристики на анализиран хидроенергетски објект.....	xvii
Карактеристики на втор реален хидроенергетски објект.....	xviii
Преглед на слики	xix
1 Глава 1 Вовед	1
1.1 Мотивација за истражувањето	1
1.2 Цели на истражувањето	2
1.3 Методологија на истражувањето	3
1.4 Организација на тема	4
2 Глава 2 Преглед на досегашните истражувања	6
2.1 Вовед	6
2.2 Моделирање на хидроенергетски објект.....	7
2.3 Управување на хидроенергетски објект со примена на пропорционално, интегрални и диференцијално управување и негова комбинација	7
2.4 Управување на хидроенергетски објект со примена на фази логика	8
2.5 Управување на хидроенергетски објект со примена на управување засновано на невронски мрежи	9
2.6 Управување со примена на машинско учење	10
2.7 Примена на машинско учење за проектирање на константите на пропорционално, интегрално и диференцијално управување	10
2.8 Управување на хидроенергетски објект со примена на комбинирани техники	11
2.9 Методологија за одредување преносна функција на турбина (идентификација на систем) преку примена на машинско учење/дигитален близнак	12
2.10 Примена на дигитален близнак кај управувачки системи	13
3 Глава 3 Математичко моделирање на хидроенергетски објект	14
3.1 Пресметка на коефициентите на реален хидроенергетски објект	18
3.2 Избор и примена на техника на управување заснована на неврронски мрежи	20
3.2.1 Дизајн на неврронска мрежа за потпомогнато управување	20
3.2.2 Математички модел на закон за управување засновано на неврронски мрежи.....	23

3.2.3	Моделирање на невронска мрежа која е директно внесена во управувачки систем	27
3.2.4	Моделирање на невронска мрежа за пресметка на константите на пропорционално, интегрално и диференцијално управување	28
3.2.5	Примена на машинско учење во процесот на подобрување на управувачките карактеристики	31
3.3	Идентификација на систем со примена на машинско учење	44
3.3.1	Рекурентни невронски мрежи	44
3.3.2	Невронска мрежа со можност за задржување на стара но важна информација подолг временски период – долга краткорочна меморија – LSTM	46
3.3.3	Алгоритам за дефинирање на дигитален близнак и методологија за идентификација на систем со невронска мрежа заснована на долга краткорочна меморија - LSTM	50
3.3.4	Повеќеслоен перцептрон - MLP	51
3.3.5	Алгоритам за дефинирање на дигитален близнак и методологија за идентификација на систем со невронска мрежа заснована на повеќеслоен перцептрон - MLP	52
4	Глава 4 Симулација на модел при црн старт на хидроенергетски објект со користење на машинско учење и управување засновано на невронски мрежи	53
4.1	Вовед	53
4.2	Изолирана работа на хидроенергетски објект	54
4.3	Линеарен модел на хидроенергетски објект	55
4.4	Нелинеарен модел на хидроенергетски објект без водостан и без влијание на еластични својства на воден столб	58
4.5	Директна примена на невронска мрежа кај изолирана работа на хидроенергетски објект	60
4.6	Дефинирање на дигитален близнак и методологија за идентификација на систем со примена на машинско учење на прв хидроенергетски објект	62
4.6.1	Примена на метода на долга краткорочна меморија и повеќеслоен перцептрон за идентификација на управувачки систем	62
4.7	Предвидување на константите на пропорционално, интегрално и диференцијално управување со помош на машинско учење	66
4.8	Методологија за одредување временска константа на вода во цевководот (Tw) со примена на машинско учење	74
4.9	Достапни податочни множества за постоечки хидроенергетски објект за формирање дигитален близнак	83
5	Глава 5 Верификација на примена на вештачки невронски мрежи и машинско учење	90
6	Глава 6 Заклучок	113

6.1	Концепт за примена на долга краткорочна меморија техника на управување.....	115
6.2	Споредба на метода на долга краткорочна меморија и метода на повеќеслоен перцептрон	116
6.3	Заклучоци од верификацијата на резултатите добиени со примена на машинско учење	117
6.4	Придонеси од истражувањето	117
6.5	Препораки за понатамошно истражување	118
Користена литература.....		120
Додаток		129

Преглед на симболи поврзани со моделирање на хидроенергетски објект

Име на ознаката	Ознака	Мерна величина
Должина на цевковод	L	$[m]$
Земјино забрзување	g	$[m/s^2]$
Временска константа на водата	T_W	$[s]$
Проток низ турбина при потполно отворен спроводен апарат	q_{base}	$[-]$
Притисок низ турбина при потполно отворен спроводен апарат	h_{base}	$[-]$
Попречен пресек на цевководот	A	$[m^2]$
Механичка моќност	P_m	$[kW]$
Површина на отвореност на лопатки на спроводен апарат	C	$[m^2]$
Коефициент на загуби во цевководот	ϕ_{fp}	$[m/(m^3/s)^2]$
Пад на притисок низ турбина	H_t	$[m]$
Единечен проток	Q_t	$[pu]$
Коефициент на засилување	A_t	$[-]$
Бездимензионален единечен притисок	h_t	$[pu]$
Бездимензионален единечен проток	q_t	$[pu]$
Проток низ турбина кога нема оптоварување	q_{nl}	$[pu]$
Коефициент на придушвање на турбина	D	$[-]$
Аголна брзина	ω	$[rad/s]$
Механичката временска константа	T_m	$[s]$
Временска константа на серво распоредник	T_A	$[s]$
Момент на инерција	$G \cdot D^2$	$[tm^2]$
Број на вртежи во минута	n_r	$[rev/min]$
Генерирана моќност	P_r	$[MW]$
Електрично оптоварување	P_l	$[kW]$
Пропорционална константа	K_p	$[-]$
Интегрална константа	K_i	$[-]$
Диференцијална константа	K_d	$[-]$
Периода на осцилации	T_u	$[s]$

Преглед на симболи поврзани со машинско учење

Име на ознаката	Ознака	Мерна величина
Параметри кои ја дефинираат мрежата	φ_i	-
Бел шум	ε_i	-
Секвенца од управувачкиот сигнал	$u(k)$	-
Влез во системот од невронската мрежа	$u(k)$	-
Излез од системот	$y(k)$	-
Број на влезови во системот што доцнат	m	-
Број на излези што доцнат	n	-
Доцнење на системот од управувачкиот сигнал и излезот од системот	d	-
Нелинеарна функција од NARMA	f	-
Нелинеарна функција од NARMA	g	-
Тежински коефициент	w_n	-
Коефициент на помест (bias)	b	-
Број на влезови во системот	n_i	-
Број на излези од системот	n_0	-
Бројот на параметри т.е. бројот на променливи	k	-
Пресметаниот број на неврони	n_1	-
Број на измерени точки	z	-
Вистинска вредност од податочното множество	y_i	-
Предвидена вредност	y_i	-
Брзина на учење	α	-
Вектор во почетен момент	m_0	-
Вектор во моментот после почетниот момент	v_0	-
Временски пресметковен чекор	t	-
Експоненцијална стапка	β	-
Влез во невронска мрежа дефиниран во временски домен кај RNN	x_t	-
Состојба во слоевите кај RNN	h_t	-
Излез од невронска мрежа во временски домен кај RNN	o_t	-
Нелинеарна активациска функција	Φ_h	-

Sigmoid AF	σ	-
Tanh AF	tanh	-
Linear AF	linear	-
Relu AF	relu	

Преглед на кратенки

Скратен запис	Целосно име на кратенката	Име на англиски
PID	Пропорционално-интегрално-диференцијално управување	Proportional-integral-derivative – PID
ANN	Вештачки невронски мрежи	Artificial Neural Network
NN	Невронски мрежи	Neural Network
ML	Машинско учење	Machine learning
MPC	Управување кој може да ги предвиди следните чекори	Model predictive controller
NARMA	Управување со автоматска регресија	Nonlinear auto regressive controller
MRC	Управување со две невронски мрежи и референтен модел	Model reference controller - MRC
AR	Автоматска регресија	Autoregressive - AR
MA	Движечки просек (слично со средна вредност)	Moving average - MA
FFNN	Невронска мрежа со движење на сигналот само по паралелна на директната патека	Feed-forward neural network
LMA	Алгоритам за оптимизација	Levenberg-Marquardt Algorithm
LR	Брзина на учење	Learning rate
w_n	Тежински коефициент	Weight
b	Коефициент на помест	Bias
AF	Активациска функција	Activation function
DT	Дигитален близнак	Digital Twin
ADAM	Алгоритам за оптимизација на пресметка - ADAM оптимизатор	Adam optimizer (Adaptive Moment Estimation)
RNN	Рекурентни невронски мрежи	Recurrent neural network - RNN
LSTM	Мрежи со можност на задржување на старата, но важна информација подолг временски период – долга краткорочна меморија	Long short-term memory (LSTM)
PLC	Програмибилен логички контролер	Programable logic controller (PLC)
MLP	Повеќеслоен перцептрон/неврон	Multilayer perceptron (MLP)
SCADA	Системите за супервизорно управување и аквизиција на податоци	Supervisory control and data acquisition (SCADA)

Карактеристики на анализиран хидроенергетски објект

Реден бр.	Карактеристика	Вредност/Мерна единица
1	Моќност на генератор при оптимална работа	50 [MVA]
2	Моќност на турбина при оптимална работа	41 [MW]
3	Оптимален проток	50 [m ³ /s]
4	Оптимален напор	92 [m]
5	Номинален проток	48,5 [m ³ /s]
6	Номинален напор	92 [m]
7	Максимален проток	50 [m ³ /s]
8	Максимален напор	110.7 [m]
9	Отвореност на спроводен апарат при оптимална работа	73.75 %
10	Максимална моќност на турбина	50 [MW]
11	Геодетска висина	106.2 [m]
12	Должина на притисен цевковод	382.355 [m]
13	Дијаметар на притисен цевковод	5 [m]
14	Временска константа на вода во цевковод T_w	1.434 [s]
15	Коефициент на загуби низ цевковод k_f	0.001071 m/(m ³ /s) ²
16	Коефициент на засилување A_t	1.1211
17	Волуменски загуби низ турбината q_{nl}	0.08 [p.u.]
18	Време на патување на бранот T_e	0.429 [s]
19	Временска константа на вода во притисен цевковод T_{wp}	1.143 [s]
20	Временска константа на водостан C_s	36.11 [s]

Карактеристики на втор реален хидроенергетски објект

Реден бр.	Карактеристика	Вредност/Мерна единица
1	Конструктивна моќност на генератор	20500 [kVA]
2	Максимална моќност на турбина	20010 [kW]
3	Номинална моќност на турбина	18200 [kW]
4	Максимален нето пад	42.4 [m]
5	Номинален нето пад	40 [m]
6	Максимален проток	53,5 [m ³ /s]
7	Номинален проток	50 [m ³ /s]
8	Должина на цевковод	31455 [mm]
9	Дијаметар на цевковод	3280 [mm]
10	Временска константа на вода во цевководот T_w	0.479 [s]
11	Коефициент на загуби во цевководот	0.000225
12	Максимална отпорност на спроводен апарат	100 %
13	Отвореност на спроводен апарат при оптимална работа	75 %
14	Коефициент на засилување A_t	1.5344
15	Волуменски загуби низ турбина q_{nl}	0.1214 [p.u.]
16	Константа ϕ_f	0.015
17	Дарисов коефициент	0.00025

Преглед на слики

Слика 1. Блок дијаграм на ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ СО ДВА ТИПА УПРАВУВАЊЕ, PID И УПРАВУВАЊЕ ЗАСНОВАНО НА НЕВРОНСКИ МРЕЖИ	14
Слика 2. Блок дијаграм за ОСТРОВСКА РАБОТА НА ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ ПОНАТАМУ РАЗГЛЕДУВАНА КАКО УПРАВУВАЧКИ СИСТЕМ	15
Слика 3. Блок дијаграм на ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ СО ПРИКАЗ НА ЛИНЕАРЕН МОДЕЛ НА ХИДРАУЛИЧНА ТУРБИНА.....	15
Слика 4. Блок дијаграм на НЕЛИНЕАРЕН МОДЕЛ НА ХИДРАУЛИЧНА ТУРБИНА	17
Слика 5. Блок дијаграм на ЕЛЕКТРИЧЕН ПОДСИСТЕМ НА ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ	18
Слика 6. Блок дијаграм на СИСТЕМ ЗА ПРИДВИЖУВАЊЕ НА СПРОВОДЕН АПАРАТ	18
Слика 7. СТРУКТУРА НА УПРАВУВАЊЕ ЗАСНОВАНА НА НЕВРОНСКИ МРЕЖИ – NARMA [77].....	25
Слика 8. СИСТЕМ СО ЗАТВОРЕНА ПОВРАТНА ВРСКА И УПРАВУВАЊЕ ЗАСНОВАНО НА NN - NARMA [77].....	26
Слика 9. TANSIG AF [80]	27
Слика 10. PURELIN AF [80].....	27
Слика 11. ЗАМЕНА НА ХИДРАУЛИЧНА ТУРБИНА СО NN.....	27
Слика 12. СТРУКТУРА НА НЕВРОНСКА МРЕЖА ЗА ПРЕСметУВАЊЕ НА КОНСТАНТИТЕ НА PID УПРАВУВАЊЕ	29
Слика 13. СТРУКТУРА НА НЕВРОНСКАТА МРЕЖА	30
Слика 14. ДВИЖЕЊЕ НА СИГНАЛОТ ПРЕКУ НЕВРОНСКАТА МРЕЖА [85].....	32
Слика 15. SIGMOID AF [80].....	34
Слика 16. LINEAR AF [80].....	34
Слика 17. RELU AF.....	34
Слика 18. TANSIG AF [89].....	34
Слика 19. АЛГОРИТАМ ЗА ДЕФИНИРАЊЕ НА КОД ЗА ПРЕСметКА НА КОНСТАНТИ НА PID УПРАВУВАЊЕ СО КОРИСТЕЊЕ НА МАШИНСКО УЧЕЊЕ.....	43
Слика 20. ПРИНЦИП НА ПРЕНЕСУВАЊЕ НА СИГНАЛ ПРЕКУ RNN	44
Слика 21. ДВИЖЕЊЕ НА СИГНАЛ ВО RNN.....	45
Слика 22. АРХИТЕКТУРА НА МОДЕЛОТ LSTM [103]	46
Слика 23. СОСТОЈБА ЗА ОДЛУКА КОЈА ИНФОРМАЦИЈА ОСТАНУВА, А КОЈА СЕ ИСФРЛА КАКО НЕПОТРЕБНА [98].....	48
Слика 24. СОСТОЈБА НА ФОРМИРАЊЕ НОВИ ВЕКТОРИ СО ЦЕЛ КЛАСИФИЦИРАЊЕ НА ИНФОРМАЦИЈАТА КАКО ВАЖНА ИЛИ НЕ ВАЖНА [98]	49
Слика 25. СОСТОЈБА НА АЖУРИРАЊЕ НА СОСТОЈБАТА ВО КЕЛИИТЕ [98]	49
Слика 26. ФОРМИРАЊЕ НА ИЗЛЕЗНИОТ СИГНАЛ [98]	50
Слика 27. ЕДИНЕЧЕН ПЕРЦЕПТРОН ПРИКАЖАН ВО ОПШТА СОСТОЈБА [105].....	51
Слика 28. МОДЕЛ ИЗРАБОТЕН ВО SIMULINK ЗА ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ И ЛИНЕАРЕН МОДЕЛ НА ХИДРАУЛИЧНА ТУРБИНА [72]	54
Слика 29. МОДЕЛ ИЗРАБОТЕН ВО SIMULINK ЗА ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ И НЕЛИНЕАРЕН МОДЕЛ НА ХИДРАУЛИЧНА ТУРБИНА [72]	54
Слика 30. ЛИНЕАРЕН МОДЕЛ НА ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ СО УПРАВУВАЊЕ ЗАСНОВАНО НА NN – NARMA ВО СПОРЕДБА СО ЛИНЕАРЕН МОДЕЛ НА ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ СО УПРАВУВАЊЕ САМО СО PID	55
Слика 31. СПОРЕДБА НА ОДЗИВИ ЗА МОДЕЛ НА ЛИНЕАРНА ТУРБИНА СО NARMA УПРАВУВАЊЕ И УПРАВУВАЊЕ СО PID	56
Слика 32. СПОРЕДБА НА ОДЗИВ ОД ЛИНЕАРЕН МОДЕЛ СО ПРИМЕНА НА NARMA УПРАВУВАЊЕ И PID УПРАВУВАЊЕ	57
Слика 33. ДЕТАЛЕН ПОГЛЕД НА ОДЗИВ ОД ЛИНЕАРЕН МОДЕЛ УПРАВУВАН И ТРЕНИРАН СО ПРИМЕНА НА NARMA	58
Слика 34. НЕЛИНЕАРЕН МОДЕЛ НА ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ СО УПРАВУВАЊЕ ЗАСНОВАНО НА NN, NARMA ВО КОМБИНАЦИЈА СО PID УПРАВУВАЊЕ	59

Слика 35. СПОРЕДБА НА ОДЗИВОТ ЗА МЕХАНИЧКАТА МОЌНОСТ ПРИ КОРИСТЕЊЕ НА КОМБИНИРАНО УПРАВУВАЊЕ - NARMA и PID и УПРАВУВАЊЕ САМО СО PID [108].....	59
Слика 36. ДИРЕКТНО ВНЕСУВАЊЕ НА НЕВРОНСКА МРЕЖА ВО МОДЕЛОТ (ЦЕЛОСНА ДИРЕКТНА ЗАМЕНА ЗА ХИДРАУЛИЧНА ТУРБИНА)	61
Слика 37. СПОРЕДБА НА ОДЗИВИ ОД МОДЕЛИ СО И БЕЗ ЗАМЕНА НА ХИДРАУЛИЧНА ТУРБИНА СО НЕВРОНСКА МРЕЖА.....	62
Слика 38. БЛОК ДИЈАГРАМ ЗА ИДЕНТИФИКАЦИЈА НА СИСТЕМ	63
Слика 39. ИДЕНТИФИКАЦИЈА НА СИСТЕМ СО ПРИМЕНА НА LSTM И MLP МЕТОДА НА ML ЗА ПРВ РЕАЛЕН ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ	65
Слика 40. ИДЕНТИФИКАЦИЈА НА СИСТЕМ СО ПРИМЕНА НА LSTM И MLP МЕТОДА НА ML ЗА ВТОР РЕАЛЕН ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ	66
Слика 41. СПОРЕДБА НА ОДЗИВИТЕ КАЈ ЛИНЕАРЕН МОДЕЛ НА ХИДРАУЛИЧНА ТУРБИНА ЗА КОНСТАНТИ НА PID УПРАВУВАЊЕТО КАЈ ПРВ ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ.....	70
Слика 42. СПОРЕДБА НА ОДЗИВИТЕ КАЈ НЕЛИНЕАРЕН МОДЕЛ НА ХИДРАУЛИЧНА ТУРБИНА ЗА КОНСТАНТИ НА PID УПРАВУВАЊЕТО КАЈ ПРВ ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ.....	71
Слика 43. СПОРЕДБА НА ОДЗИВИТЕ КАЈ НЕЛИНЕАРЕН МОДЕЛ НА ХИДРАУЛИЧНА ТУРБИНА ЗА КОНСТАНТИ НА PID УПРАВУВАЊЕТО КАЈ ВТОР ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ.....	71
Слика 44. СПОРЕДБА НА ОДЗИВИ ОД НЕЛИНЕАРЕН МОДЕЛ НА ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ СО РАСПОРЕДУВАЊЕ НА ЗАСИЛУВАЊА ЗА ВРЕДНОСТИ ДОБИЕНИ СО ML И СО МЕТОДА НА АВТОМАТСКО ПОДЕСУВАЊЕ НА КОНСТАНТИ	73
Слика 45. ПРИМЕНА НА MLP ЗА ИДЕНТИФИКАЦИЈА НА ВРЕМЕНСКА КОНСТАНТА НА ВОДАТА ВО ЦЕВКОВОДОТ $T_w=0.6322$, $T_w=0.76774798$, $T_w=0.8791$, $T_w=0.1571$ ДОБИЕНА СО ML ЗА ПРИКАЗ НА МОЌНОСТА НА ТУРБИНАТА (ПРВ РЕАЛЕН ОБЈЕКТ НА УПРАВУВАЊЕ).....	78
Слика 46. ПРИМЕНА НА MLP ЗА ИДЕНТИФИКАЦИЈА НА ВРЕМЕНСКА КОНСТАНТА НА ВОДАТА ВО ЦЕВКОВОДОТ $T_w=0.6322$, $T_w=0.76774798$, $T_w=0.8791$, $T_w=0.1571$ ДОБИЕНА СО ML ЗА ДЕТАЛЕН ПРИКАЗ НА ФРЕКВЕНЦИЈА (ПРВ РЕАЛЕН ОБЈЕКТ НА УПРАВУВАЊЕ).....	79
Слика 47. ПРИМЕНА НА LSTM ЗА ИДЕНТИФИКАЦИЈА НА ВРЕМЕНСКА КОНСТАНТА НА ВОДАТА ВО ЦЕВКОВОДОТ $T_w=0.5822$, $T_w=0.93149$, $T_w=0.2753$ ДОБИЕНА СО ML ЗА ПРИКАЗ НА МОЌНОСТА НА ТУРБИНАТА (ПРВ РЕАЛЕН ОБЈЕКТ НА УПРАВУВАЊЕ)	79
Слика 48. ПРИМЕНА НА LSTM ЗА ИДЕНТИФИКАЦИЈА НА ВРЕМЕНСКА КОНСТАНТА НА ВОДАТА ВО ЦЕВКОВОДОТ $T_w=0.5822$, $T_w=0.93149$, $T_w=0.2753$ ДОБИЕНА СО ML ЗА ПРИКАЗ НА ФРЕКВЕНЦИЈА НА ТУРБИНАТА (ПРВ РЕАЛЕН ОБЈЕКТ НА УПРАВУВАЊЕ)	80
Слика 49. ПРИМЕНА НА MLP ЗА ИДЕНТИФИКАЦИЈА НА ВРЕМЕНСКА КОНСТАНТА НА ВОДАТА ВО ЦЕВКОВОДОТ $T_w=0.195$, $T_w=0.52615$, $T_w=0.60458$ ДОБИЕНА СО ML ЗА ПРИКАЗ НА МОЌНОСТА НА ТУРБИНАТА (ВТОР ОБЈЕКТ НА УПРАВУВАЊЕ).....	81
Слика 50. ПРИМЕНА НА MLP ЗА ИДЕНТИФИКАЦИЈА НА ВРЕМЕНСКА КОНСТАНТА НА ВОДАТА ВО ЦЕВКОВОДОТ $T_w=0.195$, $T_w=0.52615$, $T_w=0.60458$ ДОБИЕНА СО ML ЗА ДЕТАЛЕН ПРИКАЗ НА ФРЕКВЕНЦИЈАТА (ВТОР ОБЈЕКТ НА УПРАВУВАЊЕ).....	81
Слика 51. ПРИМЕНА НА LSTM ЗА ИДЕНТИФИКАЦИЈА НА ВРЕМЕНСКА КОНСТАНТА НА ВОДА ВО ЦЕВКОВОДОТ $T_w=0.829$, $T_w=8602$, $T_w=87875963$ ДОБИЕНО СО ПРИМЕНА НА ML ЗА ДЕТАЛЕН ПРИКАЗ НА МЕХАНИЧКАТА МОЌНОСТ (ВТОР ОБЈЕКТ НА УПРАВУВАЊЕ)	82
Слика 52. ПРИМЕНА НА LSTM ЗА ИДЕНТИФИКАЦИЈА НА ВРЕМЕНСКА КОНСТАНТА НА ВОДА ВО ЦЕВКОВОДОТ $T_w=0.829$, $T_w=8602$, $T_w=87875963$ ДОБИЕНО СО ПРИМЕНА НА ML ЗА ДЕТАЛЕН ПРИКАЗ НА ФРЕКВЕНЦИЈАТА (ВТОР ОБЈЕКТ НА УПРАВУВАЊЕ)	82
Слика 53. ИЗМЕРЕНИ ВРЕДНОСТИ ОД ВТОР ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ (ПРИ ВКЛУЧУВАЊЕ НА ТУРБИНА) ЗА ОТВОРЕНОСТ НА ЛОПАТКИ ОД СПРОВЕОДЕН АПАРАТ (СИНА БОЈА) И ФРЕКВЕНЦИЈА (ПОРТОКАЛОВА БОЈА) ОД 08.02.2023	83
Слика 54. ИЗМЕРЕНИ ВРЕДНОСТИ ОД ВТОР ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ (ПРИ ИСКЛУЧУВАЊЕ НА ТУРБИНА) ЗА ОТВОРЕНОСТ НА ЛОПАТКИ ОД СПРОВЕОДЕН АПАРАТ (СИНА БОЈА) И ФРЕКВЕНЦИЈА (ПОРТОКАЛОВА БОЈА) ОД 08.02.2023	83

Слика 55. Податочно множество за превземено од SCADA на реалната постројка за отворност на лопатки од спроводен апарат	84
Слика 56. Податочно множество превземено од SCADA на реална постројка за генерирана механичка моќност	84
Слика 57. Смулациски модел од реалне хидроенергетски објект со два чекори за воспоставување на потребна механичка моќност при вклучување	85
Слика 58. Одзив од нелинеарен модел без водостан и PID управување при црн старт [66]	85
Слика 59. Девијација на фреквенцијата на нелинеарен модел без водостан со PID при црн старт [66]	86
Слика 60. Одзив на нелинеарен модел без водостан и со распоред на засилувања на PID при црн старт [66].....	86
Слика 61. Девијација на фреквенцијата на нелинеарен модел без водостан со распределување на засилувања на PID при црн старт [66]	87
Слика 62. Измерена излезна моќност при вклучување и исклучување на хидраулична турбина, податоци искористени за тренирање и валидирање на моделот од ML	87
Слика 63. Превземени податоци од SCADA системот за прва постројка	88
Слика 64. Шема на хидрауличната инсталација во лабораторијата за автоматика	93
Слика 65. Модел на хидраулична инсталација изработена во MATLAB/SIMULINK подготвена за пресметка во реално време со помош на B&R AUTOMATION STUDIO TOOLBOX	94
Слика 66. Лабораториска инсталација за верификација на резултатите од машинското учење	94
Слика 67. Карактеристика на распоредник за соленоид А	95
Слика 68. Карактеристика на распоредник за соленоид Б	95
Слика 69. Одзив од симулација за поместување на позиција 80 мм.....	98
Слика 70. Одзив од измерено поместување на позиција 80 мм	98
Слика 71. Споредба на одзивите од симулација и одзивите од мерење за прва група резултати за поместување на позиција 80 мм за $K_p=304$, $K_i=291$ и $K_D=308$	99
Слика 72. Одзив од симулација за поместување на позиција 60 мм за $K_p=475$, $K_i=327$ и $K_D=472$	100
Слика 73. Одзив од измерено поместување на позиција 60 мм за $K_p=475$, $K_i=327$ и $K_D=472$	100
Слика 74. Споредба на одзивите од симулација и одзивите од мерење за втора група резултати за поместување на позиција 60 мм за $K_p=475$, $K_i=327$ и $K_D=472$	101
Слика 75. Одзив од симулација за поместување на позиција 40 мм за $K_p=690$, $K_i=425$ и $K_D=576$	102
Слика 76. Одзив од измерено поместување на позиција 40 мм за $K_p=690$, $K_i=4425$ и $K_D=576$	102
Слика 77. Споредба на одзив од мерење и симулација за поместување на позиција 40 мм со $K_p=690$, $K_i=4425$ и $K_D=576$	103
Слика 78. Блок дијаграм на методата WACK-CALCULATION	105
Слика 79. WACK-CALCULATION метода за намалување на влијанието на заситувањето за 40 мм и $K_p=690$, $K_i=425$ и $K_D=576$	105
Слика 80. Одзив за постигната позиција 40 мм за трета група резултати ($K_p=690$, $K_i=425$ и $K_D=576$) со примена на WACK-CALCULATION метода	106
Слика 81. Споредба на одзив од мерење и симулација за постигната позиција 40 мм за трета група резултати ($K_p=690$, $K_i=425$ и $K_D=576$) со примена на WACK-CALCULATION метода	106
Слика 82. Споредба на одзиви од симулација со и без примена на WACK-CALCULATION метода.....	107
Слика 83. WACK-CALCULATION метода за намалување на влијанието на заситувањето за 60 мм и $K_p=475$, $K_i=327$ и $K_D=472$	108
Слика 84. Одзив за постигната позиција 60 мм за втора група резултати ($K_p=475$, $K_i=327$ и $K_D=472$) со примена на WACK-CALCULATION метода	108
Слика 85. Споредба на одзиви од симулација и мерење со примена на WACK-CALCULATION метода за поместување 60 мм	109
Слика 86. Споредба на одзиви од симулација со и без примена на WACK-CALCULATION метода за поместување 60 мм	110

Слика 87. BASK-CALCULATION МЕТОДА ЗА НАМАЛУВАЊЕ НА ВЛИЈАНИЕТО НА ЗАСИТУВАЊЕТО ЗА 80 ММ И $K_P=304$, $K_I=291$ И $K_D=308$	110
Слика 88. ОДЗИВ ЗА ПОСТИГНАТА ПОЗИЦИЈА 80 ММ ЗА ВТОРА ГРУПА РЕЗУЛТАТИ ($K_P=304$, $K_I=291$ И $K_D=308$) СО ПРИМЕНА НА BASK-CALCULATION МЕТОДА	111
Слика 89. СПОРЕДБА НА ОДЗИВИ ОД СИМУЛАЦИЈА И МЕРЕЊЕ СО ПРИМЕНА НА BASK-CALCULATION МЕТОДА ЗА ПОМЕСТУВАЊЕ 80 ММ	111
Слика 90. СПОРЕДБА НА ОДЗИВИ СО И БЕЗ ПРИМЕНА НА BASK-CALCULATION МЕТОДА ЗА ПОМЕСТУВАЊЕ 80 ММ	112
Слика 91. СПОРЕДБА НА БРЗИНА НА ПРОПАГИРАЊЕ КОН ГЛОБАЛЕН МИНИМУМ КАЈ ADAM И RMSPROP АЛГОРИТАМ НА ОПТИМИЗАЦИЈА	129
Слика 92. СПОРЕДБА НА БРЗИНА НА ПРОПАГИРАЊЕ КОН ГЛОБАЛЕН МИНИМУМ КАЈ ADAM И SGD АЛГОРИТАМ НА ОПТИМИЗАЦИЈА	129
Слика 93. КОД СО КОЈ СЕ ПРЕТСТАВУВА РАЗЛИКАТА ПОМЕЃУ ADAM И RMSPROP ОПТИМИЗАТОР	131
Слика 94. КОД СО КОЈ СЕ ПРЕТСТАВУВА РАЗЛИКАТА ПОМЕЃУ ADAM И SGD ОПТИМИЗАТОР	133
Слика 95. КОД ЗА ИДЕНТИФИКАЦИЈА НА СИСТЕМ СО ПРИМЕНА НА LSTM МЕТОДА ЗА ПРВ РЕАЛЕН ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ	136
Слика 96. ИДЕНТИФИКАЦИЈА НА СИСТЕМ СО ПРИМЕНА НА MLP МЕТОДА ЗА ВТОР РЕАЛЕН ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ	138
Слика 97. ИДЕНТИФИКАЦИЈА НА СИСТЕМ ЗА ОДРЕДУВАЊЕ НА ВРЕМЕНСКА КОНСТАНТА НА ВОДА ВО ЦЕВКОВОДОТ – TW	141
Слика 98. КОД ЗА ПРЕДВИДУВАЊЕ НА КОНСТАНТИТЕ НА PID УПРАВУВАЊЕ	142
Слика 99. ПРЕДВИДУВАЊЕ НА КОНСТАНТИТЕ НА PID ПРИ ПРИМЕНА НА GAIN SCHEDULING ТЕХНИКА НА УПРАВУВАЊЕ	146

ПРЕГЛЕД НА ТАБЕЛИ

ТАБЕЛА 1. КОЕФИЦИЕНТИ ЗА ИЗРАБОТКА НА СИМУЛАЦИЈА СОГЛАСНО МАТЕМАТИЧКИТЕ МОДЕЛИ.....	20
ТАБЕЛА 2. ДИЗАЈНИРАЊЕ НА PID УПРАВУВАЊЕ СОГЛАСНО МЕТОДАТА НА ZIEGLER-NICHOLS	29
ТАБЕЛА 3. РАЗЛИКА ПОМЕЃУ ТРЕНИРАЊЕ, ВАЛИДИРАЊЕ И ТЕСТИРАЊЕ НА МОДЕЛ	41
ТАБЕЛА 4. ПАРАМЕТРИ ЗА МРЕЖАТА ОД УПРАВУВАЊЕ ЗАСНОВАНО НА NN.....	56
ТАБЕЛА 5. ПАРАМЕТРИ ЗА МРЕЖАТА ОД УПРАВУВАЊЕТО ЗАСНОВАНО НА NN	57
ТАБЕЛА 6. ПАРАМЕТРИ ЗА МРЕЖАТА ОД УПРАВУВАЊЕ ЗАСНОВАНО НА NN КАЈ НЕЛИНЕАРЕН СИСТЕМ	60
ТАБЕЛА 7. ПРИКАЗ НА СИТЕ ПРЕНОСНИ ФУНКЦИИ ЗА ХИДРУЛИЧНА ТУРБИНА ДОБИЕНИ СО ПРИМЕНА НА ML.....	64
ТАБЕЛА 8. ПРИМЕНА НА ML ЗА ПРЕДВИДУВАЊЕ НА ВРЕДНОСТИТЕ НА PID УПРАВУВАЊЕ	68
ТАБЕЛА 9. СПОРЕДБА НА PID КОНСТАНТИ ДОБИЕНИ СО АВТОМАТСКО ПРЕСМЕТУВАЊЕ И СО ML	73
ТАБЕЛА 10. СПОРЕДБА НА RMSE И ФОРТ ПРИ РАЗЛИЧНИ КОЕФИЦИЕНТИ ЗА TW ПРИ УПОТРЕБА НА ОТВОРЕНОСТ НА СПРОВОДЕН АПАРАТ СО АКТИВНА МЕХАНИЧКА МОЌНОСТ ЗА ПРВ ХИДРОЕНЕРГЕТСКИ ОБЈЕКТ.....	77
ТАБЕЛА 11. СПОРЕДБА НА RMSE И ФОРТ ПРИ РАЗЛИЧНИ КОЕФИЦИЕНТИ ЗА TW ПРИ УПОТРЕБА НА АКТИВНА МЕХАНИЧКА МОЌНОСТ ОД ВТОРА ХИДРОПОСТРОЈКА СО АКТИВНА МЕХАНИЧКА МОЌНОСТ ОД РЕФЕРЕНТНА ХИДРОПОСТРОЈКА	77
ТАБЕЛА 12. ПОДАТОЦИ ДОБИЕНИ ЗА КОНСТАНТИТЕ НА PID УПРАВУВАЊЕТО СО РАЗЛИЧНА КОНФИГУРАЦИЈА НА НЕВРОНСКАТА МРЕЖА	96

1 Глава 1 Вовед

1.1 Мотивација за истражувањето

Мотивацијата за изработка на оваа истражување е потребата од проверка дали одредени методи на вештачки невронски мрежи (ANN), машинско учење (ML) ќе дадат позитивни резултати во однос на влијанието на динамичките карактеристики на управувачките системи како што е примената кај хидроенергетските објекти, споредено со нивната примена при препознавање на слики, текст, говор итн.

Максималното искористување на водните ресурси во еден хидроенергетски објект е голем предизвик во процесот на производство на електрична енергија. Овој предизвик е дел од еден генерален процес во кој е потребно да се земат во предвид голем број влијанија врз самиот управувачки објект. Дел од тие влијанија се минимизирање на загубите на вода, оптимизирање на работењето на хидроенергетскиот објект, земањето во предвид на составните делови на хидроенергетскиот објект како што се цевководот, спроводниот апарат, влијанието на водостан, самата турбина итн. [1].

Покрај примена на традиционалните техники за подобрување на ефикасноста и оптимизирање на работниот процес на еден хидроенергетски објект, во денешно време голема улога игра дигитализацијата на процесите [2], примената на новите техники за проектирање на законите на управување и поставување методологија за одредување на дигитален близанк (DT) на хидраулична турбина. Примената на принципите и правилата на Индустрија 4.0 може да придонесат кон стратемски решенија за подобрување и оптимизација на процесите.

Главен пристап кон проучување на управувачките системи е преку испитување и анализа на моделите добиени со примена на различни напредни, модерни техники и алгоритми од DT и симулациски модели. Развојот на технологијата, напредувањето и моќноста на компјутерите овозможува примена на современи алгоритми и софтвери во процесот на проучување и примена на софтверски алатки за оптимизација на процесите, но и подобрување на работата на делови од управувачките системи. Во овој докторски труд тоа е хидроенергетски објект. Примената на современите методи и софтверски алатки, овозможува реално-временско управување со системите и процесите, но тоа бара моќни процесори кои може истовремено да обработуваат и анализираат голем број податоци.

Примена на ANN, ML и DT се засноваат на наука за обработка на податочни множества кои преку точна комбинација на точно одредени параметри, ќе дадат важни информации за анализираниот систем. Со примена на алгоритмите на ANN, ML, DT и науката за обработка на податоци, секогаш треба да се има во предвид дека точниот резултат во најголема мера зависи од точна комбинација на параметри кои имаат иста математичка форма. Поради постоењето на голем број методи како дел од ML, целта на овој докторски труд е некои од тие методи да се искористат и применат на достапните податоци, со цел да се анализира влијанието на различни методи на ML врз динамичките карактеристики на управувачките системи кај хидроенергетски објект.

Поради постоењето на голем број методи како дел од ML, целта на овој докторски труд е некои од тие методи и алгоритми, да се искористат и применат на достапните податочни множества, со цел да се анализира нивното влијание врз динамичките карактеристики на управувачките системи кај хидроенергетски објект.

Согласно наведените карактеристики, ANN и ML се искористени за дефинирање на методологија за одредување на преносната функција на турбина преку идентификација на системи, без притоа да се користат сложени нелинеарни математички модели, туку преку науката за обработка на податоците и формирање на DT. Исто така со цел да се подобрат управувачките карактеристики на системот, ANN и ML се искористени со цел да може да се дефинира методологија за пресметување на константи на пропорционално, интегрални и диференцијално (PID) управувањето. Искористено е и управување засновано на невронски мрежи (NN) кое се смета дека дополнително може да влијае на процесот на подобрување на динамичките карактеристики на управувачките системи.

1.2 Цели на истражувањето

Основни цели на овој докторски труд се:

- Да се добијат продлабочени знаења во областа на примена на ANN, ML, DT во науката за обработка на податоци кај управувачките системи.
- Да се проучат, селектираат и да се применат некои од методите на ML со цел да се анализираат како тие влијаат на управувачките системи, на хидроенергетските објекти.
- Примена на закон за управување заснован на ANN.
- Проверка и верификација дали повеќеслоен перцептрон/неврон (MLP), долга краткорочна меморија (LSTM) и управување со автоматска регресија (NARMA) може да се искористат во реални услови.
- Примена на ANN и ML со цел дефинирање на методологија за проектирање на PID управување како би се постигнала верификација на резултатите добиени од алгоритмите на ML.
- Развивање методологија за користење на податочни множества превземени од системите за супервизорно управување и аквизиција на податоци (SCADA).
- Верификација на методата и моделот на PID управување добиено со примена на алгоритмите на ANN и ML.
- Верификација на резултати добиени со примена на различни методи на ML, детекција на аномалии при предвидувањето на параметри и константи.
- Пронаоѓање на можен начин на отклонување на аномалии кај системи кои работат со параметри предвидени со помош на алгоритмите на ML.

ML може да се подели на повеќе под гранки кои пак опфаќаат различни пристапи и различни методи за анализа и подобрување на моделите. Поради големиот број на методи, во овој докторски труд се разгледуваат само две методи, MLP и LSTM. Исто така освен наведените методи, се користи и управување заснован на NN, NARMA која пак во себе има вградено закон за управување кој во комбинација со NN треба да допринесе кон подобрување на динамичките карактеристики на управувачкиот систем.

Избраните методи се сосема различни и на сосема различен начин го обработуваат сигналот пред да се добие последната информација којашто се презентира на излез од објектот на управување. Симулациите на линеарните и нелинеарните модели се изработени во софтверскиот пакет MATLAB/Simulink. Со комбинација на достапните податочни множества преку искористување на науката за обработка на податоци направен е DT кој овозможува понатамошно анализирање и разгледување на објект на управување со примена на техниките на ML преку програмскиот јазик Python.

Верификацијата на резултатите добиени со помош на ANN, ML и DT се прави со помош на методата real-time control prototyping, каде што преку Simulink и B&R програмибилен логички контролер (PLC) се воспоставува управување на хардвер кој е достапен за реализација во лабораториски услови.

1.3 Методологија на истражувањето

За да се реализира ова истражување ќе бидат применети методи кои ќе обезбедат оптимални и нови пристапи кон реализација на научни резултати. Фокусот на овој докторски труд е примена на неколку методи од ML со цел подобрување на динамичките карактеристики на еден хидроенергетски објект, но и примената на DT преку наука со обработка на податоци.

Истражувачката методологија ќе се потпира на неколку чекори и тоа:

- Теоретски истражувања

Ќе се направи преглед на достапната научна и стручна литература поврзана со примената на ANN, ML, DT, науката за обработка на податоци кај управувачките системи, односно кај хидроенергетски објекти. Во зависност од досегашните истражувања ќе се издвои дел за кој што се достапни многу малку податоци или речиси е воопшто не обработен, па на тој начин ќе се оформи целина кон кој ќе се движи целосното истражување.

- Симулациски истражувања

После прегледот на литература и дефинирање на правецот кон кој ќе се движи истражувањето, следува оформување и преработка на симулациски модели кои ќе служат за споредба на резултатите при верификација. Целта на симулациските модели ќе биде анализа на влијанието на применетите методи од ANN, ML и DT како и влијанието на управувањето засновано на NN. Понатаму, резултатите од симулациите ќе бидат споредени со резултатите добиени од лабораториските мерења.

- Експериментални истражувања

За верификацијата на наведените хипотези од овој докторски труд ќе се користи хидраулична инсталација во лабораториски услови. Хидрауличната инсталација ќе се состои од неколку елементи и тоа хидрауличен цилиндар со двострано дејство и еднострана клипница, пропорционален 4/3 распоредник од двете страни активиран електромагнетно, пумпа, линеарен сензор за отчитување на позицијата на клипот од хидрауличниот цилиндар и мозокот на системот, PLC тип B&R. Методата real-time control prototyping се користи при верификација на резултатите од овој систем.

За квалитетно да се изработи истражувањето, достапни се голем број на податочни множества кои ќе се користат за примена на ANN, ML, DT преку науката за обработка со податоци. Еден дел од добиените податочни множества ја пресликуваат динамиката на реален хидроенергетски објект, друг дел од тие податочни множества, превземени од SCADA системот, ги пресликуваат статичките карактеристики на два различни хидроенергетски објекти.

Пред да се премини процесот на верификација, потребно е со примена на MLP и LSTM методата да се направи предвидување на параметрите на пропорционалната, интегралната и диференцијалната константа на PID. Откако ќе се добијат параметрите потребно е да се направи селекција кои од тие параметри му овозможуваат на системот подобри динамички карактеристики. Тоа е битен чекор бидејќи секој од параметрите се добива со различна конфигурација на NN. Од тука ќе може да се направи анализа која конфигурација и кој распоред на параметрите од NN даваат најсоодветни предвидувања. Исто така ќе може да се направи споредба која од методите MLP или LSTM дава резултати со поголема процентуална точност. За да може да се реализира верификацијата потребни ќе бидат софтверскиот пакет Automation Studio 4.2 за програмирање на B&R PLC, Matlab/Simulink за подготовка на симулациите и програмскиот јазик Python при спроведување на MLP и LSTM методата на ML.

1.4 Организација на тема

Овој докторски труд е поделен во шест поглавја каде што Глава 1 е вовед, цели и методологија на истражувањето, додека Глава 2 опфаќа преглед на досегашните истражувања и достигнувања на темата којашто ги обработува управувачките системи, односно во овој случај хидроенергетските објекти преку примена на различни методи од ML.

Во Глава 3 се презентирани математичките модели на хидроенергетски објект, но и математичките модели на методите на ML кои се користени во овој докторски труд, MLP, LSTM и управувањето засновано на NN. Исто така во ова поглавје математички се опишани сите карактеристики на ANN и ML како што се бројот на неврони, пресметката на квадратна грешка и пресметка на коренот на квадратната грешка, пресметка на тежинскиот коефициент – w , коефициентот на помест, големината на излезниот сигнал од влезниот слој, но и од скриените слоеви, парцијалните изводи на грешката, алгоритмот за оптимизација на пресметка. Во Глава 3 е опишан и законот за управување којшто е во комбинација со NN. Исто така математички е претставен и моделот на MLP и LSTM методата. Во оваа поглавје е претставен и алгоритмот за формирање на ANN.

Во Глава 4 се презентирани резултати од симулациските модели од целокупното истражување, а тука спаѓаат резултатите од следните анализи:

1. Линеарен модел на хидропостројка со NARMA управување.
2. Нелинеарен модел на хидропостројка без водостан и без влијание на еластични својства на воден столб при управување во комбинација со NARMA и PID .
3. Примена на ANN кај изолирана работа на хидроенергетски објект.

4. Дефинирање на DT и методологија за идентификација на систем со примена на LSTM на прв хидроенергетски објект.
5. Дефинирање на DT и методологија за идентификација на систем со примена на MLP на прв хидроенергетски објект.
6. Дефинирање на DT и методологија за идентификација на систем со примена на LSTM на втор хидроенергетски објект.
7. Дефинирање на DT и методологија за идентификација на систем со примена на MLP на втор хидроенергетски објект.
8. Методологија за предвидување на PID вредности со помош на ML.
9. Методологија за одредување временска константа на вода во цевководот (T_w) со примена на ML.

Во Глава 5 се опишани лабораториските мерења изработени со помош на експериментална инсталација поставена во Лабораторијата за автоматика на Машинскиот факултет во Скопје. Целта на овие истражувања е да се верифицира влијанието на резултатите добиени со помош и примена на ANN, ML, DT преку науката за обработка на податоци, на реален систем, како дел од хидроенергетски објект, односно спроводниот апарат којшто е составен од хидрауличен цилиндар со двострано дејство и еднострана клипница, $4/3$ пропорционален распореденик, сензор за мерење на позицијата на клипот од хидрауличниот цилиндар во зависност од доведениот напон, пумпа и филтер како составни елементи на инсталацијата. Како резултат на влијанието на ML врз резултатите, забележана е појава на integral wind-up (интегрален побег) феномен кај управувачки систем, а за истиот во оваа поглавје е прикажан и верифициран начинот за негово отстранување. Дополнително приложено е и објаснување која е причината за појава на феноменот интегрален побег при предвидување на константите со примена на ANN и ML.

Глава 6 се состои од заклучок, но и од препораки за понатамошно истражување. Поради брзиот развој на техниката и технологијата препораките за понатамошно истражување отвораат можност да се продолжи со работа на истата тема, но со различен пристап и со примена на различни техники на управување или анализа на управувачките системи.

На крај е приложен Додаток кој се состои од кодови кои се пишувани за да се добијат резултатите прикажани во Глава 4 и Глава 5.

2 Глава 2 Преглед на досегашните истражувања

2.1 Вовед

Покрај механичките карактеристики на составните елементи на еден хидроенергетски објект, пред се карактеристиките на хидрауличната турбина, важна улога игра и применетото управување. Освен хидрауличната турбина, во предвид треба да бидат земени внатрешните, надворешните влијанија и нарушувањата, еластичноста на цевководот, еластичноста на флуидот, можната појава на хидрауличен удар, променливата потреба и побарувачка на електрична енергија на мрежата. Сите овие се влијателни фактори врз работењето на хидроенергетскиот објект.

Поради специфичноста и распространетоста на полето што ги опфаќа истражувањата поврзани со конструктивните, механичките, управувачките и сите останати влијателни карактеристики на хидроенергетскиот објект, овој докторски труд го обработува делот поврзан со управувањето како важен дел од објектот со цел негово работење со најдобри перформанси. Исто така го обработува делот со подобрувањето на управувачките карактеристики преку анализа на податоците со примена на ML.

Покрај многубројните достапни техники за управување односно проектирање на закон за управување како што се преку траг на корен, Бодеова, Никвистова метода како конвенционални техники, досега најприсутно е PID управувањето или негова комбинација со константите.

Освен тоа се појавуваат истражувања со примена на фази логика во процесот на управување со хидроенергетски објект, но и примена на ANN и ML, но не во полето на управување, туку во полето на предвидување на производство на електрична енергија, предвидување на побарувачка на електрична енергија, квалитет на произведена електрична енергија при влијание на различни услови итн. Во овој докторски труд прикажана е примената на различни модели на ANN како дел од ML во процесот на дефинирање на методологија за одредување на хидраулична турбина, дефинирање методологија за проектирање на константите на PID управувањето за постигнување подобри динамички карактеристики на објектот на управување. Во дефинирање на методологиите, главна улога игра дефинирањето на DT со помош на науката за обработка на податочни множества. Преку преглед на досега достапната литература, ќе бидат прикажани голем дел од достигнувањата во однос на управување со хидроенергетски објекти, но главен акцент ќе биде ставено на влијанието на ANN и ML во процесот на дефинирање на методологија за управувачките системи, идентификација на систем итн.

Примената на ANN, како дел од ML со цел одредување на методологијата за проектирање на закон за управување, односно методологија за одредување на временската константа на хидрауличната турбина при нејзин избор, но и предвидување на константите на PID управувањето, главно ќе биде прикажано преку линеарни и нелинеарни модели на хидроенергетска постројка без водостан поради неговото занемарливо мало влијание на динамичките карактеристики при анализа на резултатите. Тука голема важност при дефинирање на методологиите ќе има и дефинирањето на DT со помош на достапните податочни множества и примена на науката за обработка со податоци.

2.2 Моделирање на хидроенергетски објект

Постојат различни типови на математички модели кои опишуваат еден хидроенергетски објект. Некои од нив се линеарни модели, дел нелинеарни, некои ги зимаат во предвид влијанието на водостанот, постоењето на притисен цевковод, некои не го зимаат во предвид влијанието на водостанот, ниту пак влијанието на цевководот итн. Во оваа истражување во предвид се земени линеарните и нелинеарните модели кои не го зимаат во предвид влијанието на водостанот, а го зимаат во предвид влијанието на притисниот цевковод и тоа само кај нелинеарните модели.

Освен симулациските модели, со примена на науката за обработка со податоци и достапните податочни множества, изработен е ДТ на објектите на управување кои исто така се користат за дефинирање на методологиите за проектирање на PID управување, методологиите за идентификација на систем, методологии за користење на податочни множества.

2.3 Управување на хидроенергетски објект со примена на пропорционално, интегрални и диференцијално управување и негова комбинација

Уште во самите почетоци при анализа на динамичките карактеристики на еден хидроенергетски објект, било незамисливо да се работи со нелинеарни модели поради слабата процесорска моќ на некогашните пресметковни машини, но и недостиг на алатки за нивно обработување и пресметување. За таа цел се обработувале само линеарните модели за кои не е потреба голема пресметковна моќ, а и самите математички изрази се поедноставни.

Но во поново време, во време на брз технолошки развој кога процесорската моќ на компјутерите овозможува пресметка и симулација на математичките модели без поголеми потешкотии, при симулација на управување со хидроенергетски објект, главен акцент се става на нелинеарните модели [3], [4], [5], [6]. За разлика од нелинеарните модели дефинирани во [4], во [7] хидрауличната турбина е попрецизно математички дефинирана. При тоа најпрво ќе бидат обработени моделите кои користат конвенционални техники на управување, PID управување, но и комбинација од PID управувањето.

Една од најшироко употребуваните техники за управување е PID управувањето. Кај хидроенергетските објект за управување со фреквенцијата исто така се користи PID, но и негова комбинација. Во [8] е претставено робустно управување со PID со цел да се обезбеди стабилност и динамички карактеристики на системот во целото работно подрачје на хидрауличната турбина. Тука PID управувањето се споредува со методата H_{∞} . Согласно приложените резултати, може да се каже дека PID како едно од наједноставните и најприменуваните методи на управување, обезбедува стабилност и динамички карактеристики споредливи и со посовремени управувачки методи. Доколку се обработува линеарниот модел на хидрауличната турбина, само пропорционално, интегрално (PI) управување допринесува до задоволителни резултати при анализа на фреквенцијата и на динамичките карактеристики [9]. Во истиот труд, освен PI управување се презентирани и други начини на користење, односно PID управување, пропорционално интегрално – пропорционално диференцијално (PI-PD), но согласно приложените анализи и резултати

дојдено е до заклучок дека PI дава најоптимално решение при споредување на побараната и вистински добиената механичка моќност.

Со цел да се постигне управување во цело работно подрачје на хидрауличната турбина се применува методата на управување со распределување на засилувања на константите на PID управувањето. Во [10] и [11] е покажано како техниката на распределување на засилувања е ефикасен метод за одредување на параметрите на PID со цел подобрување на динамичките карактеристики на управувачките системи.

Освен PID управувањето, други техники кои придонесуваат за подобрени динамички карактеристики на системот се робустно оптималното управување [12], адаптивно управување [13], управување со примена на ANN [14] итн. Дел од наведените техники ќе бидат подетално обработени во овој докторски труд.

Дополнително достапни техники за управување освен PID е complimentary sliding mode controller (CSMC) [15], односно управувачка техника која се применува пред се кај нелинеарни системи преку “принуда” да системот се движи по точно дефиниран неконтинуиран управувачки сигнал. Оваа метода пред се, се применува кај хидраулични турбини со променлив број на вртежи.

2.4 Управување на хидроенергетски објект со примена на фази логика

Развојот на технологијата и достапноста на новите техники за управување со хидроенергетски објекти, доведува до можност за примена на посовремена метода за разлика од PID, а тоа е примена на фази логика. Најчесто интелегентните пристапи за управување имаат потреба од два или повеќе влезни вредности во управувањето со примена на фази логика, но тој пристап од економска гледна точка воопшто не е применлив. Па затоа како што е прикажано во [16] се користи управување со еден влезен управувачки сигнал. Согласно анализите и резултатите презентирани во [16] и [17] направена е комбинација од управување со фази логика во комбинација со PI, а резултатите се споредени со PID управување. Согласно резултатите при управување со нелинеарен хидроенергетски објект и примена на фази логика во комбинација со PI се добиени 8 пати помало време на стабилизирање на хидрауличната турбина во споредба со примена на чисто PID управување и 15 пати помал прескок во споредба со конвенционалните PI/PID управување. Така е покажано дека примената на фази логика во комбинација со PI управување е подобро решение при управување и постигнување на стабилност на системот.

Исто така во [18][19] е прикажан пристапот за одредување на параметрите од PI управувањето, пропорционалната и интегралната константа со цел подобрување на динамичките карактеристики и подобрување на стабилноста на хидроенергетскиот објект.

Една од техниките за управување е и примена на фази логика во комбинација со PI при определување на параметрите за управување со распределување на засилувањата согласно презентираниите и анализираниите резултати во [20], [21].

Во [22] е прикажана примената на управување со фази логика за зголемување на излезната моќност преку зголемување на бројот на вртежи на хидрауличната турбина. Во овој случај се користи чисто фази логика без примена на конвенционално управување, PID или PI.

При анализа на голем број трудови кои ја обработуваат фази логиката како дел од процесот на управување со хидроенергетски објекти, може да се каже дека фази логиката во комбинација со конвенционално управување, односно PI или PID дава најзадоволителни резултати во споредба со примена само на фази логика.

Освен примената на фази логика како управувачка техника, но и примената на комбинација од фази логика со PI/PID, достапни се трудови во кои е прикажано дека примената на неуро-фази логика [23], [24], [25] за управување со фреквенцијата, односно намалување на девијација во фреквенцијата придонесува до побрзо стабилизирање на хидроенергетскиот објект.

2.5 Управување на хидроенергетски објект со примена на управување засновано на невронски мрежи

Примената на ANN како дел од ML овозможува нивна комбинација со закон за управување на било кој систем. Целта на воведување закон за управување во комбинација со ANN е со цел подобрување на динамичките карактеристики на системите, стабилноста, зголемување на ефикасноста, но и секој друг параметар кој е цел на разгледување и истражување. Не само кај управувањето со хидроенергетски објекти, широка е примената на управување засновано на NN и кај останатите управувачки системи [26].

Во [27] е прикажана примената на управување засновано на NN, NARMA со цел управување за константно одржување на ниво на вода во резервоар. Резултатите во овој труд се споредени со управување кое може да ги предвиди следните чекори (MPC), но истиот не е заснован на NN. Согласно симулациските резултати презентирани во трудот, може да се види дека управувањето засновано на NN дава далеку позадоволителни резултати отколку MPC.

Уште еден пример каде што се користи управување засновано на NN, NARMA е управување со брзината на ротирање на перките кај ветерници [28]. Од овој труд може да се види дека управувањето засновано на NN во споредба со PID или MPC ги елиминира прескоците во системот, времето на стабилизирање на системот е за 16 % помали, а во споредба со PID времето на постигнување на стационарна состојба е за повеќе од 50 % подобро.

Во [29] е прикажано управување со концентрацијата на растворен кислород во био-реактор, каде што со примена на NN се дефинира предвидувачкиот сигнал од MPC. Како и во претходните објаснувања и во овој труд се потврдува дека управувањето засновано на невронски мрежи, NARMA овозможува поефикасно управување со нивото на растворен кислород во био-реакторот.

Примената на управувањето заснован на NN, пред се NARMA, во [30] го претставува управувањето со широк спектар на нелинеарни системи со примена на генетски алгоритам. Согласно приложените резултати, се покажува дека со примена на ова управување се постигнува ефикасно управување на нелинеарните и робустни системи.

2.6 Управување со примена на машинско учење

Примената на ML е актуелна тема и техника за ефикасно и квалитетно управување со системи. Еден од примерите и трудовите во кои се применува ML е за брза детекција на грешки и проблеми во управувачките системи [31] особено кај хидроенергетските објекти поради потребата за брза реакција при појава на било каков проблем. Освен во енергетските системи, примената на ML се среќава во голем број области како што е на пример примена во здравствениот систем за негово полесно управување [32].

Друга примена на ML е за управување и оптимизација на ниво на вода во резервоари [33], [34].

2.7 Примена на машинско учење за проектирање на константите на пропорционално, интегрално и диференцијално управување

Примената на ML за одредување на константите на PID управувањето придонесува да може да се опфати поголемо работно подрачје на хидрауличната турбина. Тоа значи дека може да се направи автоматски избор на константите од PID така да објектот на управување постигне најголема ефикасност или да се овозможи автоматско прилагодување на константите преку реално-временско собирање на податоци од објектот на управување, обработување на собраните податоци во реално време и врз основа на состојбата на системот да се менуваат параметрите како би се опфатило поголемо работно подрачје на турбината. Сето тоа е возможно со примена на некоја од методите на ML. Во достапната литература постојат голем број на примени на ML со цел автоматско прилагодување на константите на PID управувањето.

Во [35] се применува ANN со два скриени слоја, но и со повратна врска од излезот од NN. Во овој труд првиот слој се користи за мрежата да може да ја научи врската помеѓу различните управувачки параметри и управувачките перформанси на системот под различни работни услови. Вториот слој се користи за проучување на односот помеѓу параметрите на работните услови и оптимизирачките управувачки параметри при различни работни услови. Со примена на двојна NN со повратен сигнал, согласно теоретските и експерименталните проби, утврдено е дека дури за 31.3% е намалено прескокнувањето при постигнување на стационарна состојба. Исто така во овој труд се наведува дека освен намалувањето на прескокнувањето, карактеристиките на системот со примена на NN во споредба со PID се речиси исти. Исто така и во [36] е искористена NN со повратен сигнал за автоматско одредување на константите од PID управувањето за подобрување на стабилноста на управувачкиот систем.

Не само за проектирање на константите на PID управувањето кај хидроенергетски објект, туку и во многу други апликации се користи некоја од методите на ML за автоматско одредување на константите на PID или негови варијации. Како што е прикажано во [37] и [38] се користи ANN за автоматска регулација на напонот кај синхрони генератори. Исто така примената на ANN при одредување на константите на PID управувањето, како што е прикажано во [39] се применува најчесто поради тоа што не е потребно да биде дефиниран математичкиот модел на управувачкиот објект туку доволно е да има квалитетно податочно множество. Преку тоа податочно множество ќе се генерира DT за анализираниот и

обработуваниот системи и на тој начин ќе може да се помогне при проектирање на константите на PID.

За реално-временска примена на ANN и ML при прилагодување на константите на PID управувањето кај нелинеарните системи, теоретски осврт е презентираан во [40][41].

2.8 Управување на хидроенергетски објект со примена на комбинирани техники

PID управувањето е најчесто присутна техника кај управувачките системи. Тоа е конвенционален и може да се каже наједноставен и најекономичен начин на управување. Освен PID, се почесто се среќаваат најразлични комбинации на посовремени техники како што се комбинација на фази-PID, фази-неуро или неуро-PID управување. Секоја од овие техники си носи свои предности, но и недостатоци.

Една од примените на fuzzy-PID е одредување на константите на PID управувањето само при појава на надворешни влијанија кои го вадат системот од стабилна состојба со цел стабилизирање и негово враќање во стационарна состојба. Овој метод најчесто се нарекува прилагодлив фази-PID кој најчесто на објектот на управување, ML овозможува подобри динамички карактеристики и подобрена стабилност доколку се споредува само со примена на фази логика или само со PID [42], [43], [44], [45], [46]. Оваа техника се применува не само кај системи со голема важност за општеството туку и кај мали проекти кои користат микроконтролери како што се Arduino ATmega [47], [48] и слични бидејќи начинот на програмирање односно креирање на софтвер кога станува збор за мал систем со мала база на податоци е прилично едноставно.

Во [49] е прикажан пристап за примена на фази логика во комбинација со управување засновано на ANN со цел фино прилагодување на излезните динамички карактеристики при појава на ненајавени промени во оптоварувањето на мрежата.

Во [50] е прикажана примена на неуро-фази управување кај меѓусебно поврзани четири енергетски системи, два хидроенергетски објекти и два термо објекти. Во овој труд се презентирани и анализирани резултати од кои може да се види дека периодот на стабилизирање на постројките е подобар при користење на комбинацијата од неуро-фази во споредба само со фази или само со управување засновано на NN.

Една од предностите како што е опишано во многу литератури па и во [51], [52], [53] што се наведува при користење на современите техники на управување е тоа што не е потребно математичко моделирање на постројките за да може истите да се управуваат туку едноставно доволно е големо и квалитетно податочно множество за да може алгоритамот правилно да ги обработува податоците и да може да приложи добри резултати и анализи.

Примената на неуро-PID техника за управување со хидроенергетски објект во периодот на истражување и преглед на дотогашните достигнувања, сеуште не беше пронајден, па затоа во овој докторски труд главен фокус е ставен на комбинацијата на неуро-PID техника, но и примената на ANN и управување како засебна гранка како би се постигнале подобрувања во динамичките карактеристики, ефикасноста и стабилноста кај хидроенергетскиот објект.

Главен недостатокот кога се работи со неуро техника е потребата од голема процесорска моќ која бара достапност на информациите и податоците во реално време. Истото може да се каже и за примената на фази логика поради тоа што и тука е потребна голема процесорска моќ за да може да се обработат податоците. Но засега неуро техниката е водечка бидејќи квалитетот на добиени решенија и начинот на анализа на решенијата зависи од големината и квалитетот на податочното множество.

2.9 Методологија за одредување преносна функција на турбина (идентификација на систем) преку примена на машинско учење/дигитален близнак

Идентификација на еден систем подразбира примена на наука за обработка на податоци за изнаоѓање/градење DT на динамички систем со помош на податочни множества превземени од вистински модел за соодветен разгледуван систем. Со помош на примената на различни методи на ANN и ML преку анализа и обработка на податочното множество со помош на науката за обработка со податоци, може да се направи идентификација на систем без решавање на нелинеарни диференцијални равенки. Притоа за ваков пристап кон идентификација на систем, потребно е точна комбинација на потребни параметри и нивна точна анализа. Притоа во овој докторски труд, идентификацијата на систем се користи за да се одреди математичкиот модел на хидраулична турбина со цел подобрување на динамичките карактеристики на хидроенергетскиот објект.

Во [54], [55] е опишана примената на DT со цел идентификација на делови од хидроенергетски објект со цел детекција на аномалии или аларми. Во овој докторски труд, претставена е методологија за идентификација на математички модел на хидраулична турбина со примена на некои од методите на ML, односно формирање на DT со користење на податочното множество од еден хидроенергетски објект.

Постојат истражувања во кои може да се види како со примена на ML се врши предвидување на работата на турбината [56] каде што во базата на влезни и целни податоци се земени во предвид динамички карактеристики на турбината за подолг временски период, статичките карактеристики на турбината исто така за подолг временски период, но и познати идни случувања кои самите оператори врз основа на долгогодишно искуство знаат дека истите ќе се случат. Соодветната и точна комбинација на влезните и излезните параметри, значи точно предвидување на активностите на управувачкиот систем.

Друг пристап за примена на ANN и ML е преку детекција на аномалии при работа за различни брзини на отварање и затварање на лопатките од спроводниот апарат [57]. Во оваа истражување не се прави идентификација на систем, но се користи ML за моделирање на систем за детекција на аномалии. Друго истражување е направено за оптимизација на работата на хидроенергетскиот објект [58] во кое повторно не е вклучена идентификацијата на системите, но работи на дефинирање на модел за оптимално работење на хидроенергетскиот објект.

Во досега обработените трудови, но и достапните истражувања не е направена идентификација на хидраулична турбина ниту пак на било кој дел од еден хидроенергетски објект. Врз основа на достапните податочни множества, направени се анализи пред се за

предвидување за понатамошните чекори при производство на електрична енергија, предвидување на можни аномалии при работа на делови од хидроенергетскиот објект, предвидување на појава на вибрации итн.

Примената на ML кај хидроенергетските објекти опфаќа големо подрачје на истражување, но најбитно е изборот на соодветна метода и изборот на соодветен дел од управувачкиот објект за кој е можно да се соберат голем број на податоци за подолг временски период и во континуитет.

2.10 Примена на дигитален близнак кај управувачки системи

Примената на DT кај управувачките системи се почесто наоѓа широка примена при нивна оптимизација, симулација и анализа [59], [60]. Во основа, причината за постоењето на DT е појава на фузија помеѓу физичкиот систем и науката за обработка на податоци.

Во [59], [61] се користи DT како можност за мониторинг на состојбата на механички систем врз основа на која ќе може да се менува управувачката стратегија. Тоа е постигнато преку создавање на DT на повратната врска на системот преку која континуирано се набљудува излезната состојба од управувачкиот систем.

Најголем дел од задачите кои е потребно да се извршуваат се носење одлуки за одредени процеси, следење и предвидување на настаните инт. Постоењето на моќни процесори, развојот на обработка на дигитални сигнали, примената на податочни множества со голем зафатнина, не секогаш води кон развој на методологија за управување со системите кои се засноваат на методите на ANN, ML или DT [62], [63], [64].

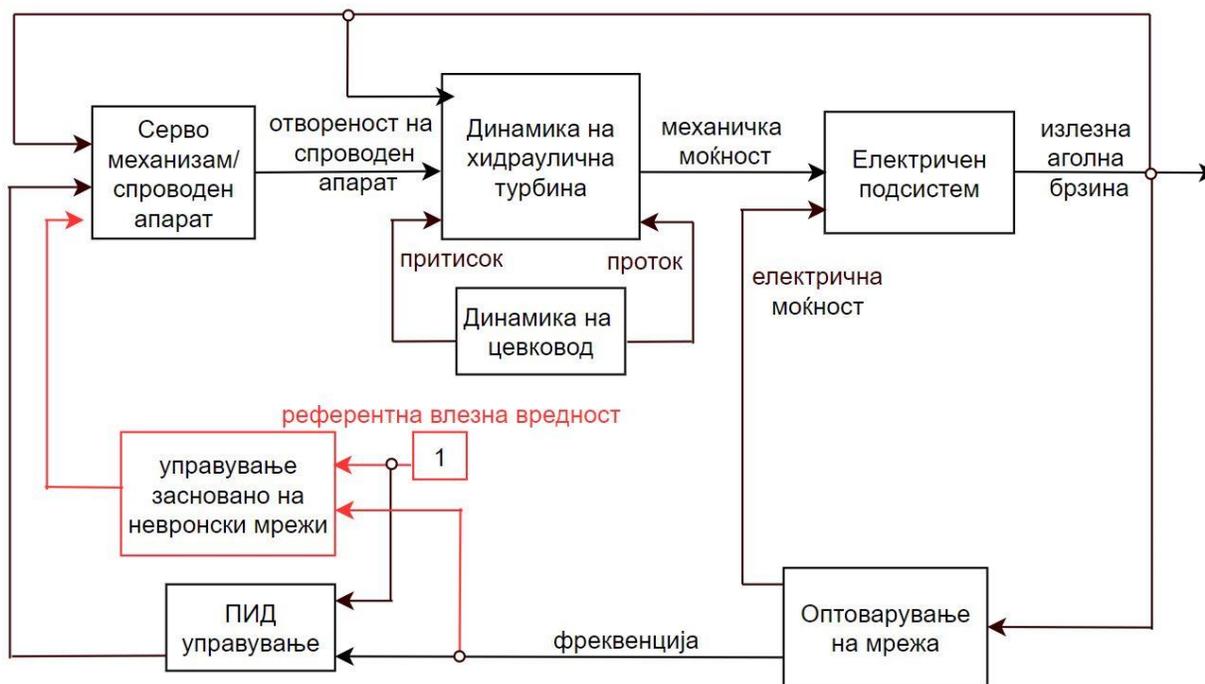
Кога станува збор за употреба на DT во процесот на управување со системите, сеуште е неистражена област и тоа прашање останува отворено.

3 Глава 3 Математичко моделирање на хидроенергетски објект

Моделите кои се користат за ова истражување се линеарни и нелинеарни модели на хидроенергетски објект, а пред се нелинеарни моделите во кои не се земени во предвид еластичните својства на водениот столб како и должината на цевководот бидејќи во [65] е покажано дека кај хидроенергетските објекти со краток доведен цевковод и среден пад, влијанието на еластичните својства на водениот столб и притисниот цевковод е занемарливо мало.

Разгледуван е и моделот со водостан со цел да се покаже влијанието на ANN и ML во процесот на подобрување на динамичкото однесување на објектот на управување, но и промената на ефикасноста.

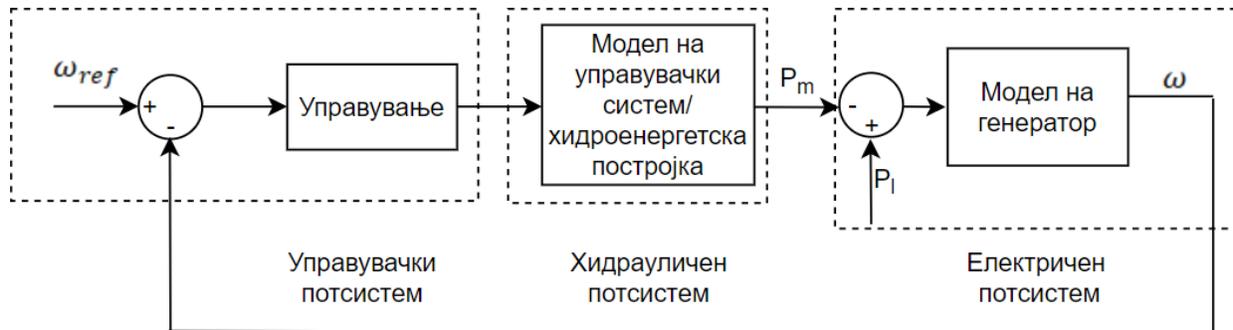
На Слика 1 е прикажан блок дијаграм на хидроенергетски објект во кој се земени во предвид спроводниот апарат, хидрауличната турбина, електричниот потсистем, оптоварувањето на мрежа и управувањето. Управувањето како што е претставено на Слика 1 е PID како прва метода и управување засновано на NN како втора, алтернативна метода.



Слика 1. Блок дијаграм на хидроенергетски објект со два типа управување, PID и управување засновано на невронски мрежи

Модел на хидроенергетски објект што ги опфаќа спроводниот апарат, хидрауличната турбина и електричниот потсистем, математички се опишува со равенките прикажани во овој доктори труд, а согласно [66].

Согласно општиот приказ на хидроенергетска постројка како на Слика 1, на Слика 2 е прикажано управувањето на турбина како составен дел од хидроенергетски систем со еден од законите на управување претставен во Глава 3 и 4 и електричен потсистем.



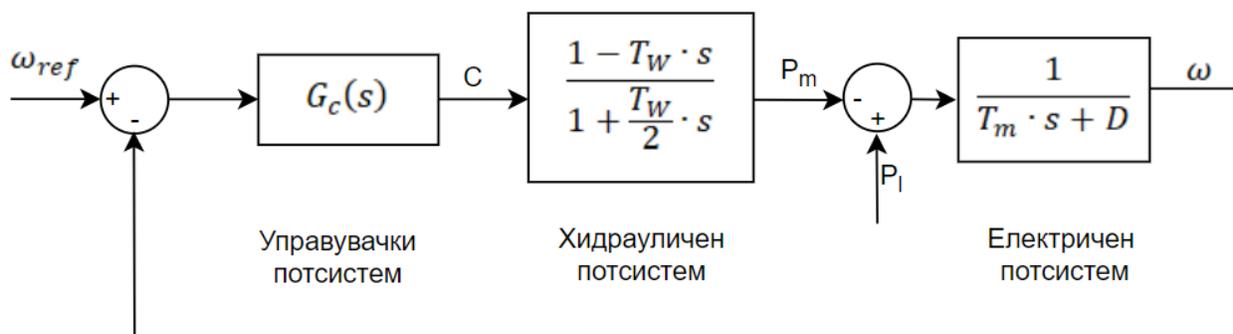
Слика 2. Блок дијаграм за островска работа на хидроенергетски објект понатаму разгледувана како управувачки систем

Линеаризиран модел на хидрауличната турбина без водостан прикажана на Слика 3 се претставени со равенките како во [66], [67]. Со тие равенки се дефинира зависноста помеѓу генерираната механичка моќност и отвореноста на спроводниот апарат. Во равенка 1, T_w е временска константа на вода во цевководот, а нејзината вредност зависи од повеќе параметри и тоа од должината на цевководот L , протокот низ турбината при потполно отворен спроводен апарат q_{base} , притисокот h_{base} , попречниот пресек на цевководот A и земјиното забрзување g . Равенка број 1 го опишува начинот на пресметување на временската константа T_w .

$$T_w = \frac{L \cdot q_{base}}{A \cdot g \cdot h_{base}} \quad (1)$$

$$\frac{\Delta P_m}{\Delta c} = \frac{1 - T_w \cdot s}{1 + \frac{T_w}{2} \cdot s} \quad (2)$$

Теоретски дефинирано, временската константа на вода во цевководот се дефинира како време потребно протокот во цевководот да помине од нула во q_{base} кога притисокот пред турбината ќе добие вредност h_{base} [66].



Слика 3. Блок дијаграм на хидроенергетски објект со приказ на линеарен модел на хидраулична турбина

Притисокот низ турбината има зависност од протокот дефинирана преку карактеристиката на вентилот и тоа:

$$Q_t = C \cdot \sqrt{2gH_t} \quad (3)$$

каде што C е површината на отвореноста на лопатките од спроводниот апарат, а H_t е притисок низ турбина.

Моќноста на турбината е пропорционална на производот од протокот и притисокот, а зависат од коефициентот на полезно дејство. За да се земе во предвид дека коефициентот на полезно дејство не е 1, вкупниот проток низ турбината кога нема оптоварување е q_{nl} .

$$P_m = A_t h_t (q_t - q_{nl}) \quad (4)$$

Коефициентот на засилување A_t е внесен поради доведување на равенките во единечна големина во однос на моќноста на генераторот, а се пресметува по следната равенка:

$$A_t = \frac{P_m}{h_t (q_t - q_{nl})} \quad (5)$$

$$A_t = \frac{\text{моќност на турбина (MW)}}{\text{моќност на генератор (MVA)} h_t (q_t - q_{nl})} \quad (6)$$

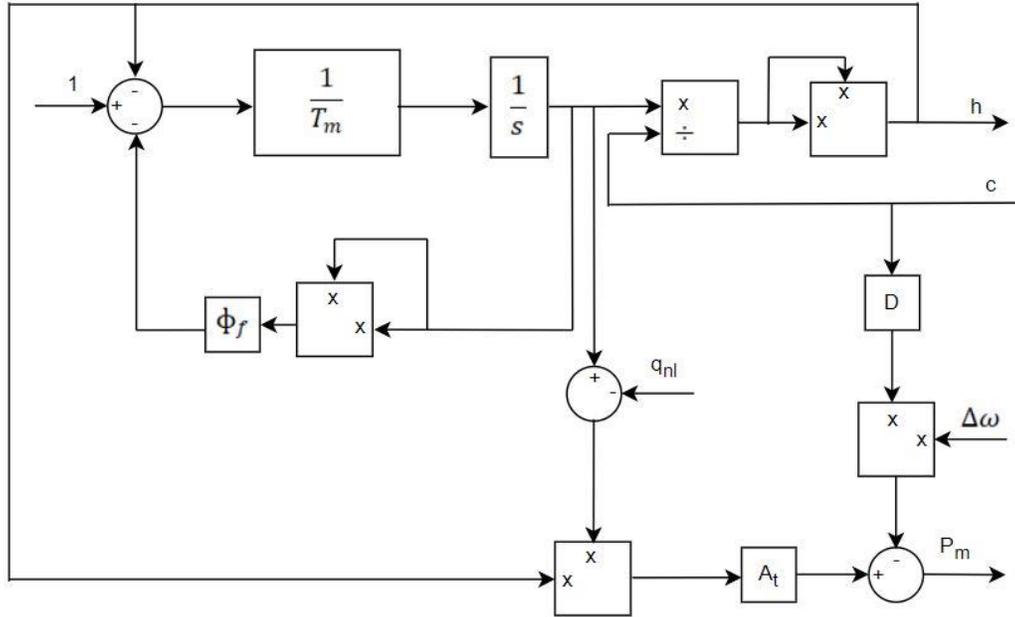
Од равенка 5 и 6, h_t е бездимензионален единечен притисок, q_t е бездимензионален единечен проток и q_{nl} е проток низ турбина кога нема оптоварување.

Доколку во равенката 4 се внесе и придушувањето кое зависи од отварањето на спроводниот апарат, во тој случај равенката за моќност на турбината за било кое оптоварување ќе биде:

$$P_m = A_t h_t (q_t - q_{nl}) - Dc \Delta \omega \quad (7)$$

каде што D е коефициентот на придушување на турбина, а $\Delta \omega$ е разлика помеѓу референтната и реалната аголна брзина на генераторот од хидрауличната турбина.

Сите равенки од 1 до 7, вклучувајќи ги и равенките од 8 до 11, го прикажуваат нелинеарниот модел на хидраулична турбина чиј што блок дијаграм е прикажан на Слика 4. Разликата помеѓу Слика 3 и Слика 4 е во тоа што на Слика 3 е претставен блок дијаграм за линеарен модел на хидраулична турбина, додека на Слика 4 е претставен блок дијаграм на нелинеарен модел на хидраулична турбина, но со исти управувачки подсистем и електричен подсистем како и моделот од Слика 3. Значи, на местото на хидрауличниот подсистем прикажан на Слика 3 е вметнат нелинеарниот модел на хидраулична турбина како што е прикажано на Слика 4.



Слика 4. Блок дијаграм на нелинеарен модел на хидраулична турбина

Преносната функција што го опишува механичкото движење на една машина поврзана со оптоварувањето и со соодветно придушување D_f е претставено со равенка 8 [66].

$$\Delta P_m - \Delta P_e = (T_m \cdot s + D_f) \Delta \omega \quad (8)$$

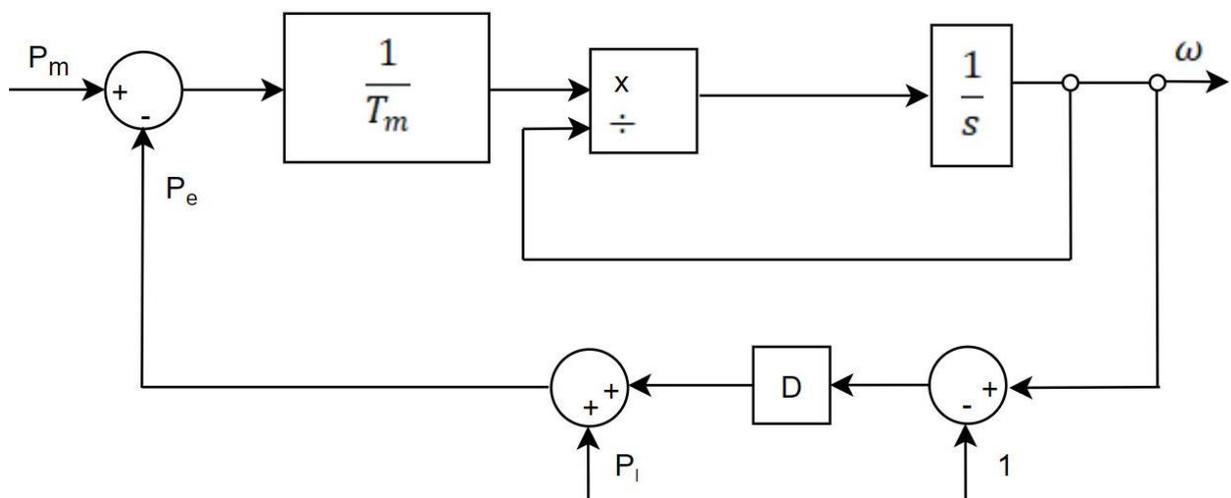
Електричниот потсистем согласно Слика 5 се состои од енергетски систем, генератор, моќноста пренесена помеѓу нив и промените на оптоварувањето на мрежата. Истиот се претставува со равенките 9, 10 и 11.

$$\dot{\omega} = \frac{1}{T_m \omega} (P_m - P_e) \quad (9)$$

$$P_e = P_l + D(\omega - 1) \quad (10)$$

$$P_m - P_e = T_m \cdot s + D_f \quad (11)$$

Во овие равенки, ω е аголната брзина со која што ротира генераторот, P_l е оптоварување на мрежа, односно нарушување, P_e е генерирана електрична енергија, T_m е механичката временска константа чија што вредност зависи од бројот на вртежи на генераторот, но и согласно тоа се пресметува според равенките дефинирани во [68].

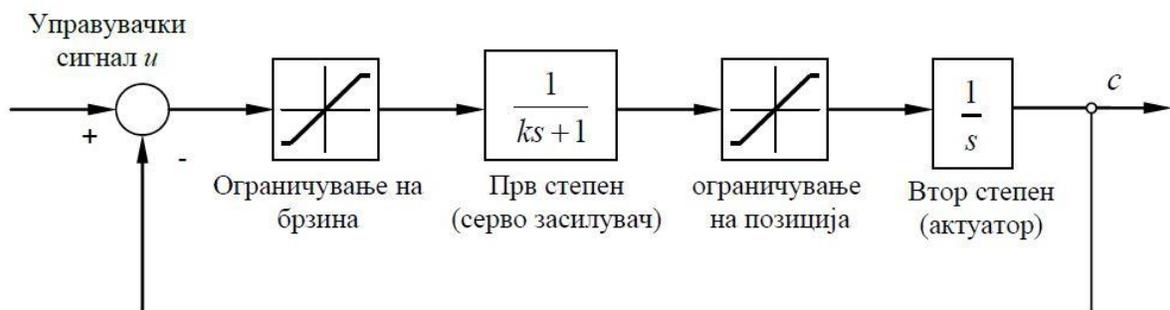


Слика 5. Блок дијаграм на електричен подсистем на хидроенергетски објект

Моделот на спроводниот апарат е претставен преку преносна функција прикажана со равенка 12 [67]

$$\frac{1}{(1+s \cdot T_A)^2} \quad (12)$$

каде што T_A е временска константа на серво распоредникот. На Слика 6 е претставен блок дијаграм на системот за придвижување на спроводниот апарат.



Слика 6. Блок дијаграм на систем за придвижување на спроводен апарат

Водостанот не се зима во предвид поради краткиот притисен цевковод, а во однос на тоа неговото влијание е мало и занемарливо врз динамичките карактеристики на хидроенергетскиот објект како што е докажано во [66].

3.1 Пресметка на коефициентите на реален хидроенергетски објект

Со цел да се потврди концептот на примена на ANN и ML во процесот на идентификација на системот, но и предвидување на константите на PID управувањето со единствена цел, подобрување на динамичките карактеристики на хидроенергетскиот објект преку задавање на статички карактеристики како влезови и целни излези, направена е пресметка на

коэффициентите на реален хидроенергетски објект кон модел со различни статички, динамички и физички параметри.

Прилагодувањето кон постоечки управувачки објект значи пресметка на следните параметри: механичка временска константа T_m , временска константа на вода во цевководот T_w , коефициент на засилување A_t , волуменски загуби низ турбина q_{nl} , коефициент на триење на цевководот ϕ_p . Освен наведените параметри, големо влијание имаат и појдовните параметри како што се: конструктивната моќност на генераторот, максималната моќност на турбината, номиналната моќност на турбината, максималниот нето пад, номиналниот нето пад, должина на цевковод, дијаметар на цевковод, површина на цевковод, парови полови на генератор итн.

За да се пресмета механичката временска константа, равенка 13, согласно препораките од 2019 дефинирани во [68] е

$$T_m = \frac{2.74 \cdot G \cdot D^2 (10^{-3} n_r)}{P_r} \quad (13)$$

каде што T_m е механичката временска константа, $G \cdot D^2$ е момент на инерција, n_r е број на вртежи во минута и P_r е генерирана моќност во мегавати MW.

Временската константа на водата исто така се менува во зависност од моќноста на генераторот. Истата се пресметува преку равенка број 14 [69].

$$T_w = \frac{Q}{H} \sum \frac{L}{gA} \quad (14)$$

Големината на временската константа на водата за турбини со моќност од 50 до 300 MW, се движи од 0,9 до 2,6 [s] [69]. Но, временската константа на водата многу зависи и од должината на цевководот L , така да за кратки притисни цевководи, $T_w < 3$ [s]. Во разгледуваниот случај на реална постројка, должината на притисниот цевковод е 31455 мм. Во равенка број 14, со Q е означен проток низ турбина при потполно отворен спроводен апарат, L е должина на притисен цевковод, A е попречен пресек на цевководот, g е земјиното забрзување и H е статички притисок низ турбина.

Коефициентот на волуменските загуби низ турбината, q_{nl} како важен елемент при дефинирањето на пресметковниот модел зависи од процентуалната отвореност на спроводниот апарат. При прилагодување на моделот, голема улога игра и коефициентот на засилување A_t .

Во Табела 1 се претставени коефициентите потребни за изработка на симулациите согласно дефинираните математички модели во софтверскиот пакет Simulink. Исто така во точка 9 се зададени вредностите на пропорционалната, интегралната и диференцијалната константа за реалните управувачки системи, постројка 1 и постројка 2.

Табела 1. Коефициенти за изработка на симулација согласно математички модели

Ред. Бр.	Коефициент	Ознака	Постројка 1	Постројка 2	Величина
1	Временска константа на вода во цевководот	T_w	1,434	0,479	s
2	Механичка временска константа на генераторот	T_m	8,3	5,420142	s
3	Конструктивна моќност на генераторот		50	20,5	MVA
4	Коефициент на линиски загуби низ цевководов	ϕ_f	0.027383	0,015	pu
5	Волуменски загуби низ турбината	qnl	0,08407	0,1214	pu
6	Коефициент на пригушување на турбина	D	0,75	1	/
7	Коефициент на засилување	At	1,1211	1,5344	/
8	Временска константа на серво распоредник	T_A	0,07	0,07	s
9	Проопорционална константа Интегрална константа Диференцијална константа	Kp Ki Kd	Kp= 2 Ki= 0,465 Kd= 1,06	Kp= 3,4 Ki= 0,465 Kd= 3,6	/

3.2 Избор и примена на техника на управување заснована на невронски мрежи

3.2.1 Дизајн на невронска мрежа за потпомогнато управување

Врз основа на изборот на модели кои ќе се користат како објект на управување, извршен е избор на управување односно примена на закон за управување кој ќе управува со фреквенцијата односно брзината на ротирање на осовината на генераторот од хидрауличната турбина. Извршена е симулација на статички и динамички карактеристики кои влијаат на моделите, а добиените резултати се споредени со резултатите претходно добиени и верифицирани со примена на конвенционалните методи на управување [65] кај линеарни и нелинеарни модели.

Покрај целокупната хидромеханичка опрема, управувањето како дел од еден хидроенергетски објект, игра важна улога во процесот на производство на електрична енергија. Поради тоа, со текот на годините направени се голем број на истражувања од областа на управувањето и негова примена кај хидроенергетски објекти, при што секогаш со појавата на современа техника и напредна технологија чија што примена во главно го подобрува однесувањето на хидрауличниот систем, главна цел е да ги подобри динамичките карактеристики кои се од голема важност како што е стабилноста, а и однесувањето на системот при режими на големи промени во оптоварување на мрежа. Покрај PID управувањето како конвенционална, популарна и најприменувана техника [4], [70][71], [24]

во поново време достапни се управувачки техники кои се сметаат за посовремени, понапредни, а исто така се смета дека овозможуваат посигурна експлоатација и управување на еден хидроенергетски објект.

Хидроенергетските објекти се високо нелинеарни објекти чии што карактеристики многу лесно може да се променат и тоа поради оптоварувањето на мрежата кое понекогаш не може да се предвиди. Како високо нелинеарни и комплексни модели, ќе се направи избор на тип на современо управување чии што резултати ќе се споредат со резултатите добиени од конвенционалното PID управување, а исто така современите техники на управување ќе се споредат и со техниката за распоред на засилувања (gain scheduling), како понапреден пристап кон управувањето во споредба со PID, пред се кај хидроенергетските објекти кои имаат променливо работно подрачје. Gain scheduling во овој докторски труд ќе се искористи како техника за управување во целосното работно подрачје на хидрауличната турбина, наместо во една работна точка, иако реалниот објект на управување функционира со примена на PID. Управување со распоред на засилувања значи користење на засебно PID управување за секоја промена посебно, но и пресметување на константите на PID при секоја промена посебно. Во суштина повторно станува збор за PID управување, но со различни вредности при процесот на вклучување на турбината па се до постигнување на стационарна состојба. Целта е да се направат симулациски испитувања за да се види дали примената на техниката на распоредување на засилувања ќе даде резултат со одзиви кои ќе овозможат оптимално искористување на водените ресурси. Таквите испитувања се направени, прикажани и анализирани во [72]. Со примена на ML направено е предвидување на вредностите на константите на PID управувањето за секој чекор посебно при примена на gain scheduling. Резултатите од симулациите ќе бидат прикажани и анализирани во Глава 4.

Споменатите современи техники на управување опфаќаат примена на управување засновано на NN кој се стреми да го линеаризира секој нелинеарен модел со цел на излез од објектот да се добие посакуваниот одзив, односно ги зема во предвид претходните вредности кои се битни за управувачкиот објект за да ги предвиди следните трендови (nonlinear auto regressive moving average - NARMA). Друг пристап е директно внесување на NN во моделот со цел да се подобрат управувачките карактеристики иако директно внесената NN не е поврзана со закон за управување. Тоа значи дека NN во целост заменува некој дел од хидроенергетски објект со цел да се анализираат соодветни состојби на објектот на управување. Споменатите закони за управување во овој докторски труд се применети на линеарни и нелинеарни модели. Кај овие модели се разгледува и разработува управување со моќноста која директно влијае на фреквенцијата на објектот. Треба да се напомене дека при проектирање и подесување на параметрите кај современите техники на управување, секој модел има свои соодветни параметри кои треба да бидат генерирани со цел да може моделот заедно со управувањето понатаму да се тренира за да се добијат посакуваните излези. Големо внимание треба да се обрати и на прилагодување и оптимизирање на параметрите кои се дел од NN, а кои во голема мера влијаат на добиените резултати.

Дополнително, освен законот за управување засновано на NN, споредени се резултатите добиени со користење на техниката за распоредување на засилувања во споредба со параметрите добиени со помош на Ziegler-Nichols во комбинација со NN за да се добијат пропорционалната, интегралната и диференцијалната константа од PID управувањето со најмала можна квадратна и процентуална грешка. Тоа би овозможило подобрување во параметрите кои понатаму се применуваат со помош на техниката за распоредување на засилувања. Тука може да се применат два пристапи, првиот пристап е веќе споменатиот, со примена на Ziegler-Nichols методата да се дефинира односно да се ограничи подрачјето во кое се движат вредностите на константите на PID, а со примена на методите на ANN и ML, да се издвојат најсоодветните вредности, односно константите со најмала квадратна грешка. Вториот пристап е да се генерира податочно множество со случајни вредности, со што ограничувањето на константите на PID управувањето при обработка на податоците, тренирање, учење и предвидување на вредностите би се намалило. Вториот пристап е добар со цел да се тестира влијанието на техниките на ANN и ML кон избирање на соодветни вредности на константите на PID кога ограничувањето е намалено.

Исто како и кај управувањето кое се заснова на ANN, за дефинирање и соодветно дизајнирање на NN, потребно е да бидат соодветно избрани голем број на параметри кои се од голема важност при добивањето на крајните пресметки и решенија. Тие параметри се нарекуваат хиперпараметри.

Хиперпараметрите го контролираат процесот на учење, но и најмногу влијаат на него. Префиксот хипер значи дека влијанието на овие параметри е од многу голема важност. Дел од хиперпараметрите се следни: број на неврони во секој слој поединечно, број на скриени слоеви, тип на активациска функција (AF) чија цел е да му обезбеди соодветна динамика на невроните во секој слој посебно, тип на оптимизатор, број на епохи, големина на серија на примероци кои ќе бидат испратени преку невронската мрежа во исто време (batch size), голема улога игра и функцијата според која ќе се одреди грешката во системот – квадратна грешка, брзина на учење (learning rate) кој е битен составен дел во алгоритмот за оптимизација на една функција.

Поставувањето на соодветен број на неврони е важно бидејќи од тоа зависи дали мрежата ќе учи соодветно. Доколку има мал број на неврони кој не е соодветен во однос на комплексноста на моделот, мрежата нема да може соодветно да ги спореди влезните и излезните параметри и истите да ги спроведе во излезна информација. Доколку пак има преголем број на параметри, мрежата исто така нема да може да направи генерализирање на излезните резултати односно нема да има решение кое конвергира.

Бројот на скриени слоеви зависи од комплексноста на моделот којшто се обработува. Доколку станува збор за високо нелинеарен модел, потребно е да има минимум една или повеќе скриени слоеви за да може нелинеарноста на моделот да се прилагоди на целната крива (target curve).

AF се важни бидејќи од нив зависи големината на излезот од неврнот што е влез во неврнот во следниот слој. AF и дава на NN нелинеарност и динамика. Доколку не се постави AF, во тој случај ќе се работи со податочното множество со линеарна зависност.

Бројот на епохи е важен бидејќи од тоа зависи колку пати податокот, односно неговата вредност поминува преку податочното множество кое е одвоено за тренирање на мрежата.

Брзината на учење е хиперпараметар што се користи за управување со темпото со кое алгоритмот ги ажурира или ги учи вредностите на NN.

Соодветниот избор на тип на оптимизатор е многу важен бидејќи од оптимизаторот зависи како ќе се ажурираат коефициентот на помест и тежинските коефициенти (weights), а од тоа зависи и големината на квадратната грешка.

3.2.2 Математички модел на закон за управување засновано на невронски мрежи

Постојат повеќе типови на управување засновани на NN како посовремена техника за подобрување на динамичките и статичките карактеристики на еден објект на управување. Кај сите типови управување засновани на NN, единствена цел е на излез од системот да се добие посакуваниот одзив и тоа подобрен во однос на одзивот што може да се добие со примена на конвенционалното управување. За таа цел постојат три типа управување засновано на NN и тоа управување кое може да ги предвиди следните чекори (model predictive controller - MPC) [73], управување кое се стреми да ги линеаризира моделите и на излез да се добие посакуваниот одзив во зависност од излезот од објектот на управување и референтниот влез (nonlinear auto regressive controller - NARMA) [73] и управување кое исто така се стреми на излез да се добие посакуваниот одзив со помош на две NN, едната за тренирање на објектот на управување, а втората за тренирање на самото управување со цел да се прилагоди на секоја ново настаната состојба (model reference controller - MRC) [74].

Како управување со речиси најкратко време за пресметка на моделите, се користи NARMA. При статистичка анализа на временски зависни податочни множества, ARMA моделот овозможува послаб стационарен стохастички процес и тоа кога е потребно да се употребат два полинома. Едниот за автоматска регресија или AR и вториот за моделирање на еден полином со една променлива или MA (moving average). Математичкиот модел за автоматската регресија е дефиниран со равенка 15,

$$X_t = \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t \quad (15)$$

каде што φ_i се параметрите кои се влез во мрежата, ε_t е бел шум. Тие параметри се независни и со идентично нарушување доколку секоја случајна променлива има исто можно нарушување како и другите променливи и сите тие променливи заедно се независни [75], [76].

Моделирањето на еден полином со една променлива математички е прикажано со равенка 16,

$$X_t = \mu + \varepsilon_t + \sum_{i=1}^q \Theta_i \varepsilon_{t-i} \quad (16)$$

каде што Θ_i се параметрите на моделот, μ е очекуваната вредност добиена од X_t и ε_t е бел шум. Тие параметри се независни и со идентично нарушување доколку секоја случајна променлива има исто можно нарушување како и другите променливи, па сите тие променливи заедно се независни [75], [76].

Доколку се спојат тие два полинома заедно, во тој случај ќе се добие математички запис со две функции согласно равенка 17 каде што p и q се две функции [75], [76].

$$X_t = \varepsilon_t + \sum_{i=1}^p \varphi_i X_{t-i} + \sum_{i=1}^q \Theta_i \varepsilon_{t-i} \quad (17)$$

Овој тип на управување не е препорачливо да се користи во ситуации кога е потребно да се постигне адаптивно управување поради нелинеарната зависност на управувачките влезови [73]. Преку равенка (18), претставен е поедноставениот математички запис на NARMA управувањето

$$y(k+d) = f[y(k), y(k-1), y(k-n+1), u(k), (k-1), (k-m+1)] \quad (18)$$

каде $u(k) \in R$ е секвенца од управувачкиот сигнал, а $y(k) \in R$ е секвенца од излезот од системот [77].

Во горенаведениот израз, $u(k)$ е влез во системот, $y(k)$ е излез од системот, додека m го претставува бројот на влезови во системот со одложено влијание (што доцнат), n е бројот на излези со одложено влијание (што доцнат), d го претставува доцнењето на системот од управувачкиот сигнал и излезот од системот [77]. Бројот на влезови со одложено влијание се однесува на претходните вредности за секој од параметрите кои понатаму се користат да се направи предвидување на конечниот излез. Влезовите со одложено влијание помагаат да се долови динамичкото однесување на системот со текот на времето, имајќи предвид како минатите влезови влијаат на сегашната/моменталната состојба. Бројот на излези со одложено влијание се однесува на претходните вредности кои понатаму се користат да се направи предвидување на конечниот излез. Тоа му овозможува на управувањето да разбере како минатите/претходните излези придонесуваат за тековниот излез, со што се подобрува точноста на предвидувањето на излезите, но и предвидување на перформансите на системот.

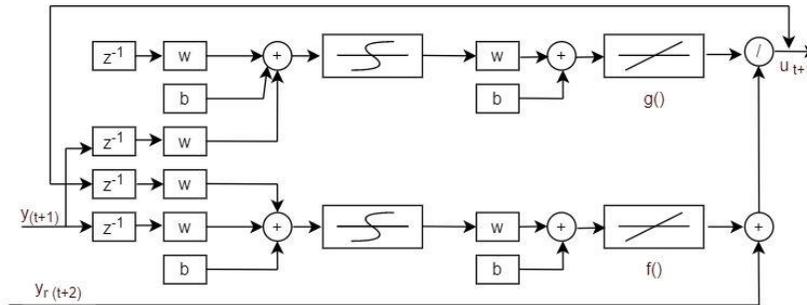
NARMA се карактеризира преку Тејлоровиот израз за скалар $u(k) = 0$, па во тој случај, математичкиот модел за апроксимација е дефиниран преку равенките (19), (20) и (21).

$$y(k+d) = f[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)] + g[y(k), y(k-1), \dots, y(k-n+1), u(k-1), u(k-m+1)] \cdot u(k) \quad (19)$$

$$f = F[(y(k), \dots, y(k-n+1), 0, u(k-1), \dots, u(k-m+1))] \quad (20)$$

$$g = \left. \frac{\partial F}{\partial u(k)} \right|_{(y(k), \dots, y(k-n+1); u(k)=0, u(k-1), \dots, u(k-m+1))} \quad (21)$$

NARMA се состои од две нелинеарни функции, f и g кои се моделираат со помош на две невронски под мрежи. Двете функции имаат $(2n - 1)$ влезови кои се минати вредности од излезот од системот y и управувачкиот сигнал u . Штом ќе се направи апроксимација на нелинеарниот систем, управувачкиот сигнал е дизајниран на тој начин што се елиминираат двете нелинеарни функции f и g , а излезот $y(k + d)$ е еднаков на референтниот влез $y_r(k + d)$ во објектот на управување. Штом односот помеѓу управувачкиот сигнал и излезот од објектот на управување е во форма на алгебарска линеарна равенка, управувачкиот сигнал кој што произлегува од излезот, но и од референтниот влез во објектот на управување, е лесно одредлив [77][78], [30]. f е нелинеарна функција која ја опишува врската помеѓу тековниот излез и минатите влезови и излези на системот. Оваа функција ја доловува динамиката на системот, вклучувајќи ги и неговите нелинеарни карактеристики. Точноста и ефективноста на NARMA во голема мера зависат од тоа колку добро f може да ја претстави вистинската динамика на системот. Прецизен модел на f му овозможува на управувањето точно да ги предвиди идните излези, што е од суштинско значење за ефективно управување.



Слика 7. Структура на управување заснована на невронски мрежи – NARMA [77]

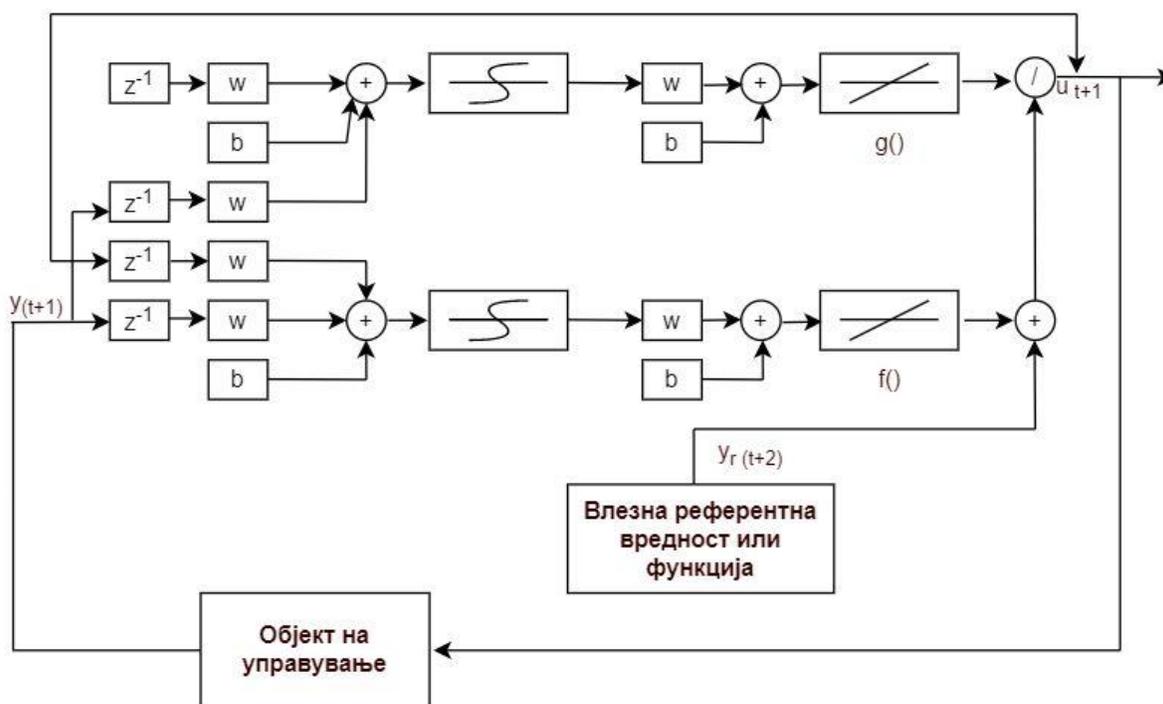
Со цел да се изгради управување засновано на NN како што е NARMA, бројот на задоцнети влезови и излези од управувачкиот објект се избираат врз основа на структурата на објектот којшто се разгледува и управува, додека пак бројот на скриени слоеви се бира на начин да се направи најточна апроксимација на нелинеарниот објект на управување. Два чекори се битни при изградбата на NARMA управувањето засновано на NN и тоа: идентификација и управување [77].

Идентификација на објектот на управување значи дека тој не се тренира во реално време, врз основа на достапното податочно множество, влезови и излези со кои се располага со цел апроксимација на нелинеарните функции f и g . Откако ќе се направи апроксимација, влезниот сигнал е изедначен со излезниот сигнал и во тој случај нелинеарноста и динамиката на еден систем се поништени [73], [77].

Управувањето се заснова на законот за управување како што е покажано со равенка (22).

$$u(k+1) = \frac{y_r(k+d) - f[y(k), \dots, y(k-n+1), u(k), \dots, u(k-n+1)]}{g[y(k), \dots, y(k-n+1), u(k), \dots, u(k-m+1)]} \quad (22)$$

Кога нелинеарните функции f и g ќе се моделираат, управувањето засновано на NN е дефиниран така да законот за управување прикажан со равенка (22) има примена во процесот на добивање на посакуваниот одзив на излез од системот.

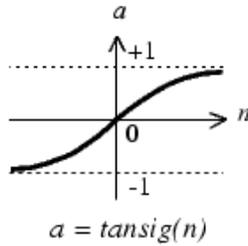


Слика 8. Систем со затворена повратна врска и управување засновано на NN - NARMA [77]

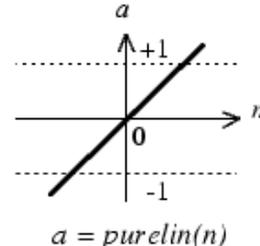
Во овој тип управување засновано на NN, NARMA, како референтен влез во системот единствено може да се искористи константна вредност, пред дефинирана функција (единечна отскочна, единечна рампа, синусоида итн.), додека управувачкиот сигнал не е возможно да се дефинира како влез во системот поради тоа што излезот од објектот на управување мора да се спореди со веќе позната и функција која не се менува со текот на времето.

Кога се користи овој метод, употребуваниот алгоритам е back-propagation, метода каде што сигналот се движи по повратна патека, кој што се користи за тренирање на NN кај која движењето на сигналот е само во една, патека паралелна на директната патека (feed-forward neural network) - FFNN, додека алгоритамот за оптимизација кој работи во својство на back-propagation методата е Levenberg-Marquardt Algorithm (LMA) [79].

Користењето на NARMA има одредени ограничувања како на пример AF кои се пред дефинирани преку управувањето засновано на NN и тоа tansig и purelin. Тие се исти со AF секогаш кога се гради NN кога типот на алгоритмот на ML е супервизорно, тип линейарна регресија.



Слика 9. Tansig AF [80]

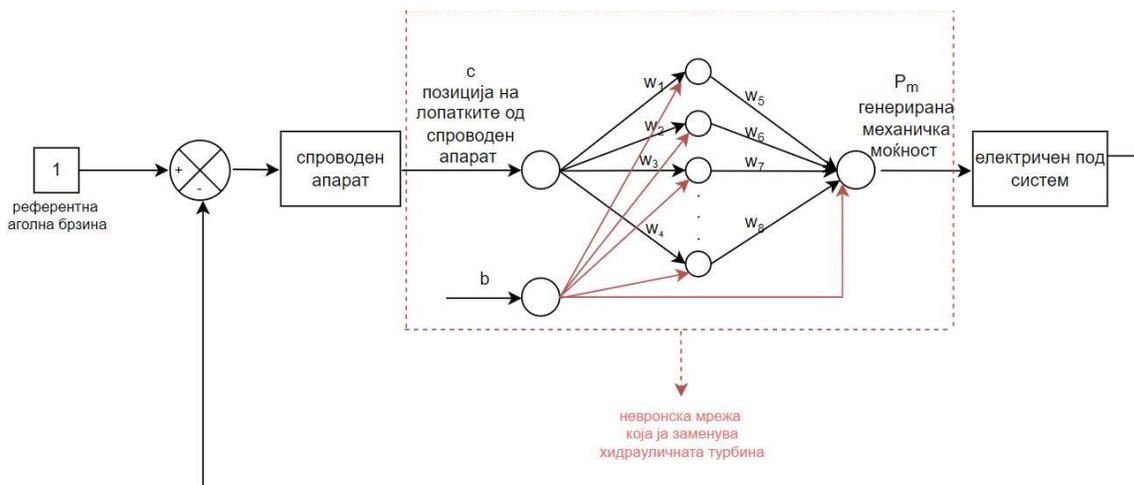


Слика 10. Purelin AF [80]

Tansig е AF што обично се користи за решавање на реални постројки. Во ова истражување, тоа е многу важно бидејќи моделот е реален и верифициран. Користењето на оваа функција ќе го претставува сигналот, излезот од системот помеѓу -1 и +1. Purelin само ја поништува нелинеарноста во системот.

3.2.3 Моделирање на невронска мрежа која е директно внесена во управувачки систем

Директно внесување на NN во системот значи замена на еден од моделираните под системи од објектот на управување директно со NN. Не замена со управување заснован на NN туку чиста NN без воведен закон за управување. Влезовите и излезите од мрежата се дефинирани така што соодветствуваат со симулацискиот модел. Бидејќи хидрауличната турбина се заменува со NN, влез во мрежата е отвореност на спроводен апарат, додека излез од NN ќе биде генерираната механичка моќност P_m . Податочните множества за моделот на влезот и излезот од NN се земени од веќе измерени податоци од реален, постоечки објект. За да се испита влијанието на NN врз динамичките карактеристики на хидроенергетскиот објект, направени се симулации во софтверскиот пакет MATLAB/Simulink.



Слика 11. Замена на хидраулична турбина со NN

На Слика 11 е прикажано директното внесување на NN во DT - замена на хидрауличната турбина. Целта на создавање DT и негово внесување во системот е да се види дали може да замени објект како дел од целина, притоа најпрво да се пресликаат истите карактеристики и влијанија на моделот, а подоцна да се овозможи и подобрување на динамичките карактеристики на објектот на управување. За таа цел, типот на мрежата што е искористена е 1:3:1. Првиот слој е влезниот којшто се состои од еден неврон, односно тоа е податочно множество со кое се опишува позицијата на лопатките од спроводниот апарат. Како тече сигналот, на ред доаѓа скриен слој со три неврони, а потоа и излезниот слој со еден неврон односно излез од системот, а тоа е генерираната механичка моќност. Согласно равенката број 24, за пресметка на минимален и максимален опсег во кој што треба да се движат бројот на неврони во еден слој, но и согласно расположливите податочни множества, минималниот број на неврони во скриениот слој треба да биде помало или еднакво (\leq) од четири. Дефинирањето на точниот број неврони и скриени слоеви во NN е од особено значење бидејќи несоодветното поставување на параметрите може да доведе до overfitting или underfitting, што го доведува во прашање функционирањето на NN, но и резултатите што истата би ги испорачала. За додавање динамика на NN, потребно е да се дефинира AF на секој од слоевите посебно. Во скриениот слој е дефинирана tansig AF, додека во излезниот слој е дефинирана purelin AF. Алгоритамот за оптимизација којшто се користи за NN при моделирање во Simulink е LMA. Од достапните алгоритми за оптимизација во софтверскиот пакет MATLAB/Simulink, наведениот обезбедува најдобри перформанси на системот [81], [82].

Бидејќи хидрауличната турбина може да се опише со линеарни, но и со нелинеарни математички модели, нелинеарноста на турбината во случај кога се користи ML е занемарлива бидејќи истата независно дали се работи со линеарниот или нелинеарниот модел, целосно се заменува со NN моделирана со помош на достапното податочно множество. Во NN, нелинеарноста од математичкиот моделот не се зима во предвид бидејќи таа работи со однапред дефинирани податочни множества, измерени или превземени податоци. Резултатите се презентирани во поглавје 4.

3.2.4 Моделирање на невронска мрежа за пресметка на константите на пропорционално, интегрално и диференцијално управување

Целта на пресметката на константите на PID управувањето, K_p, K_i, K_d , е да се зголеми ефикасноста на системот и да се подобрат динамичките карактеристики на хидроенергетскиот објект. Пресметувањето на константите на PID управувањето првично е дефинирано преку методата на Ziegler-Nichols, со цел да се добие границата во која може да се движат константите, а потоа со примена на NN да се селектираат и одвојат само оние кои имаат најмала квадратна грешка.

Најпрво примената на Ziegler-Nichols е согласно правилата кои се дефинирани во [83], а тоа значи дека најпрво K_i и K_d се поставуваат да бидат еднакви на нула, така што останува само K_p . Вредноста на K_p се дефинира на тој начин што се зголемува се до точка кога објектот на управување ќе почне да осцилира, односно ќе почне да се движи во форма на константна синусоида, а притоа осцилациите нема да почнат да се намалуваат. Таа точка се

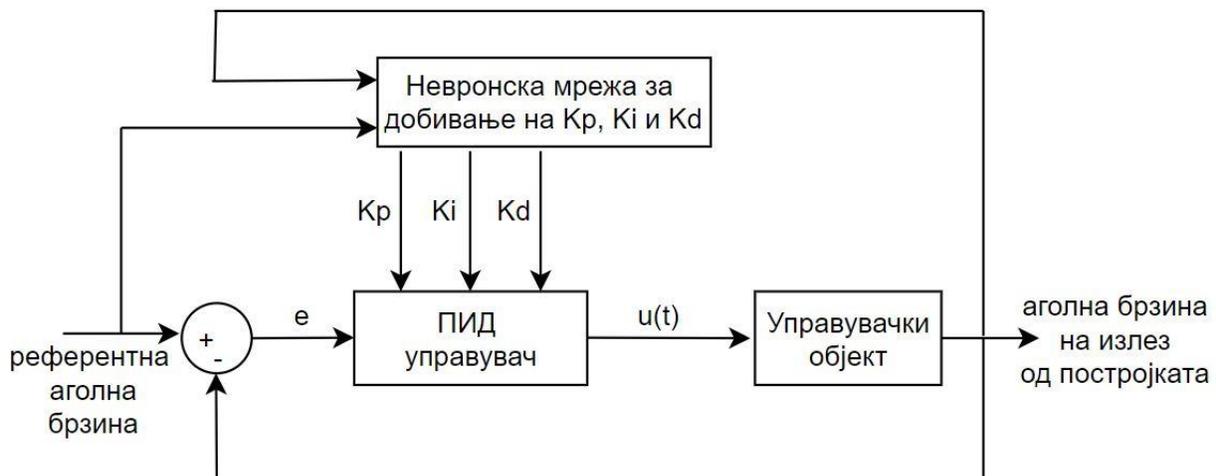
дефинира како точка K_u . Периодата на осцилациите е дефинирана како T_u . Согласно дефинираните константни параметри, со цел соодветно да се дизајнира PID управувањето, се користи Табела 2.

Табела 2. Дизајнирање на PID управување согласно методата на Ziegler-Nichols

Форма на управување	K_p	K_i	K_d
PID	$0.6 \cdot K_u$	$1.2 \frac{K_u}{T_u}$	$0.075 \cdot K_u \cdot T_u$

На тој начин се дефинираат минималната и максималната граница за константите на PID управувањето. Целта на дефинирање на K_p, K_i, K_d константите е нивно дефинирање како целни/таргет вредности во NN со цел да се одреди најсоодветната комбинација која ќе се добие преку дефинирање на најмала квадратна грешка.

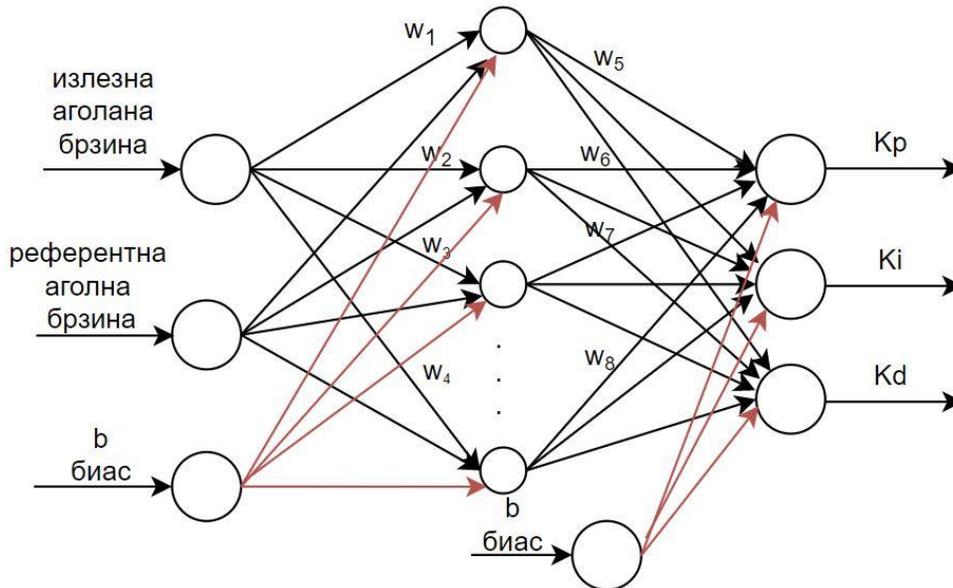
Со цел да се дизајнира NN, најпрво се дефинираат нејзините влезови, а тоа се измерената аголна брзина ω_{out} и референтната аголна брзина ω_{ref} . Излез односно како целните/таргет вредности се дефинираат различни сетови за K_p, K_i, K_d согласно добиените горни и долни гранични вредности. Комбинацијата на константите кои го дефинираат PID управувањето со најмала квадратна грешка ќе биде избрана како најсоодветна, а потоа ќе биде применета во дел од моделите со цел да се потврди дали избраните параметри добиени со примена на NN ќе овозможат подобрување на ефикасноста и подобрување на динамичкото однесување на системот.



Слика 12. Структура на невронска мрежа за пресметување на константите на PID управување

За пресметување на константите на PID управување, структурата на NN претставена на Слика 12 е составена од еден слој со два неврони во кој се дефинирани влезовите на

системот, еден скриен слој (слој со променлив број на неврони) и излезниот слој во кој се дефинирани целните/таргет вредности за кои се прави пресметка.



Слика 13. Структура на невронската мрежа

Како што е прикажано на Слика 13, мрежата е од тип каде што информацијата од еден неврн во слојот се поврзува посебно со секој неврн од наредниот слој. Поради тоа што се работи за модел во кој се истражуваат динамичките карактеристики, но и фреквенцијата на хидроенергетскиот објект при црн старт, оптоварувањето на турбина се претставува преку 6 различни чекорни влезови се додека не се постигне стабилна состојба, односно 50 Hz или 1 како нормализирана вредност. Со таа цел, за секој чекорен влез постои посебна NN, така што за секој чекорен влез посебно се дизајнира NN со различни вредности за константите на PID управувањето. Бидејќи како што системот се движи према стабилна состојба, така е поголема улогата и влијанието на PID управувањето, но така е и покомплексна можноста за одредување на соодветни константни вредности чии што влијанија ќе ја подобрат ефикасноста и динамиката на објектот на управување.

Освен дефинирањето на типот на NN, соодветниот избор на хиперпараметри има големо влијание на излезните резултати.

Соодветната комбинација од сите наведени хиперпараметрите ќе даде добар и соодветен дизајн на една NN. Бидејќи брзината на учење, бројот на неврони, бројот на епохи и бројот на серијата примероци немаат меѓусебна математичка поврзаност, едноставно нивните вредности е потребно да бидат соодветно прилагодени при процесот на дизајнирање на NN. Секое големо отстапување во било кој од наведените параметри го доведува во прашање крајниот резултат при примена на NN.

3.2.5 Примена на машинско учење во процесот на подобрување на управувачките карактеристики

Примената на современи техники на управување во процесите е се почесто тема на истражување. Целта за нивна примена и употреба е можноста за подобрување на перформансите, динамички карактеристики, ефикасност и друго во зависност од разгледуваниот управувачки системи.

Развојот на нов, модерен управувачки систем подразбира прилагодување на објектот на управување кон секоја ново настаната состојба во која тој може да се најде во било кој момент од времето. Ваквиот систем исто така може да располага со големо податочно множество кој понатаму со помош на соодветен алгоритам се обработува и на крај го дава најсоодветниот резултат согласно структурата на алгоритамот [84]. ML тука ќе се користи како техника за подобрување на управувачките карактеристики, стабилноста и континуирано подобрување на одзивите на излез од системот. За таа цел се искористени NN со цел проектирање на константите на PID управувањето. За таа цел за овој проблем е избрана FFNN. Овој тип на мрежа се користи тогаш кога влезните податоци се движат од лево спрема десно односно од влезот спрема излезот, само во еден правец преку невроните и слоевите.

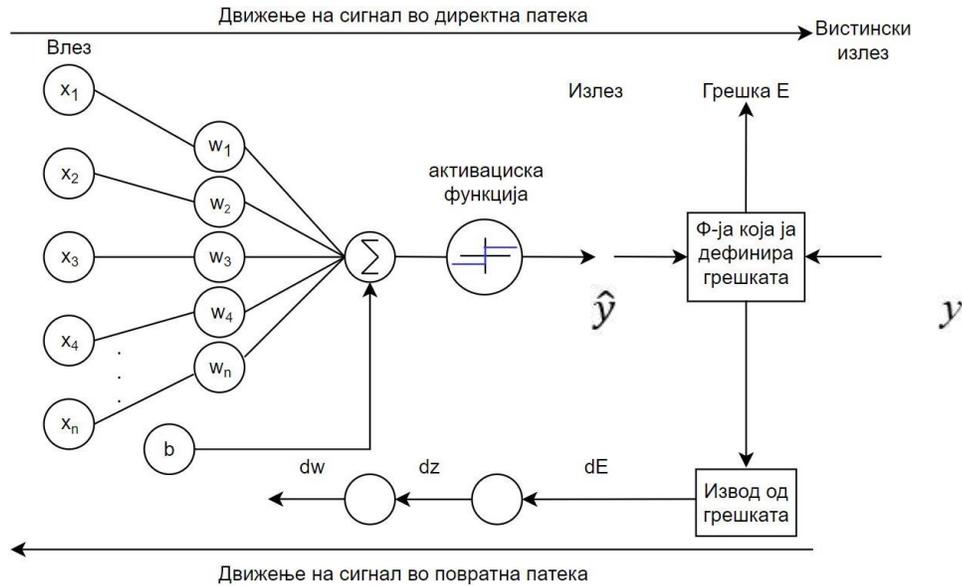
Примената на ML во процесот на управување со системите подразбира избор и дизајн на хиперпараметри со цел добивање резултати кои влијаат на подобрувањето на перформансите на објектот на управување.

Постојат повеќе типови алгоритми за ML, но во овој докторски труд, согласно достапните податочни множества, измерените параметри и бројот на обработени податоци кои се дефинираат како влез и излез во NN, типот на алгоритамот на ML е супервизорно, тип линеарна регресија која во овој случај се користи за оптимизација на процес.

Најпрво е потребно да се анализира достапното податочно множество, да се направи селекција на потребните податоци и да се комбинираат параметрите што се потребни да се анализираат со примена на ML. Потоа се дефинираат влезовите во NN. Согласно Слика 14 влезовите во мрежата се означени со x_1, x_2, \dots, x_n . Од секој неврон кој што всушност означува посебен влез во NN излегува сигнал со соодветна големина на тежинскиот коефициент (weight) - w_n , чија големина на почетокот се задава како случајна вредност во граница од 0 до 1, а потоа со тренирање на NN, големината на сигналот автоматски се менуваат се додека не се постигне бараниот резултат. Не постои начин како да се пресмета почетната вредност на големината на сигналот w_n , па затоа едноставно се задава случајна вредност во дефинираните граници. Освен тежинскиот коефициент w_n , на процесот на оптимизација влијае и коефициентот на помест b , кој најчесто преку AF внесуваат динамика на слојот, помагаат во процесот на оптимизација со цел побрзо да се достигне локалниот минимум. Во дефинираната NN за пресметување на константите на PID управувањето, коефициентот на помест, во почетен момент е поставен да биде нула, а со тренирањето на мрежата истиот се менува во вредност од нула до еден. Сигналот што е комбинација од големината на сигналот, а потекнува од секој неврон посебно и од

коэффициентот на помест, математички може да се запише на следниот начин, како што е претставено со равенката број 23.

$$z = w_1 \cdot x_1 + w_2 \cdot x_2 + \dots + w_n \cdot x_n + b \quad (23)$$



Слика 14. Движење на сигналот преку невронската мрежа [85]

За време на тренирањето на мрежата, како што е прикажано на Слика 14 постојат две главни фази и тоа движење на сигналот по паралелна на директната патека (forward propagation) и движење на сигналот по повратна патека (backpropagation). Движењето на сигналот по директна патека значи дека податочното множество што е дефинирано на влез во системот се води по директна патека преку сите слоеви низ целата NN. Тоа значи дека движењето на сигналот по директна патека почнува од влезот во системот, а завршува со пресметување на грешката помеѓу влезот и дефинираните целни излези. Додека пак движењето на сигналот по повратна патека е најбитниот дел кој го опфаќа тренирањето на мрежата. Тренирањето на мрежата го опфаќа процесот на fino подесување на тежинскиот коефициент (weight), којашто се заснова на пресметаната грешка во однос на изборот на соодветната оптимизирачка функција, а притоа извршувајќи се во претходната итерација т.е. епоха. Главната цел на движење на сигналот по повратна патека е да се подобри точноста на мрежата, а во исто време да се намали грешката преку употребата на соодветен алгоритам за оптимизирање [85].

Откако ќе биде дефинирано, податочното множество како влез и целни излези во NN, потребно е да се одреди бројот на неврони во секој од слоевите. Постои равенка со која може да се пресмета границата на бројот на неврони кои би се дефинирале во мрежата, но сепак согласно динамиката на системот, вредностите добиени од таа равенка може да претрпат промени преку натамошно рачно прилагодување.

Преку равенката 24 се пресметуваат најниската и највисоката граница на бројот на неврони во една NN.

$$2 \cdot (n_i + n_o) \leq n_1 \leq \frac{k \cdot (n_i + n_o) - n_o}{n_i + n_o + 1} \quad (24)$$

Тука n_i е бројот на влезови во системот, n_o е бројот на излези од системот, k е бројот на параметри т.е. бројот на променливи и n_1 е пресметаниот број на неврони. Минималната и максималната граница на број на неврони со коишто би можела една NN да се валидира, тестира и тренира, зависи од бројот на измерени податоци, односно зависи од бројот на влезни и целните излезни параметри во NN.

Дефинирањето на типот на оптимизатор, а понатаму и неговото однесување во голема мера зависи и од изборот на тип на AF, бидејќи од нив зависи дали при тренирање на мрежата ќе се менуваат/прилагодуваат тежинскиот коефициент и коефициент на помест или би се менувала само големината на сигналот. Најчесто големината на сигналот се менува во граница од 0 до 1, додека коефициентите на помест (bias) најчесто остануваат непроменети, односно има вредност од 0 до 1 во текот на целиот процес од почеток, па се до добивање на резултатот.

Постојат голем број на AF [86] од кои зависи прилагодувањето на големината на сигналот, а понатаму и на излезот од системот.

Со цел подобрување на динамичките карактеристики на хидроенергетскиот објект, но и пресметување на константите на PID управувањето, при дизајнирање на NN, искористени беа AF sigmoid/tanh за првиот скриен слој доколку се користи Python за дизајн на NN или sigmoid/tansig доколку се користи софтверскиот пакет MATLAB/Simulink, додека AF искористена во невроните на излез од мрежата е relu доколку NN се дефинира во Python, или linear доколку се користи софтверскиот пакет MATLAB/Simulink.

Примената на sigmoid AF, е поради тоа што оваа функција ја зема во предвид било која реална вредност како влез или излез во граница од 0 до 1. Колку што е поголема вредноста на влезниот сигнал, толку е излезот поблиску до 1, односно колку е влезниот сигнал помал, толку излезот е поблиску до 0, како што е прикажано на Слика 15. Математичката презентација на sigmoid AF е зададена со равенка 25. Оваа AF е избрана поради тоа што при прилагодување на сигналот, неговата големина ќе се движи во границите само од 0 до 1, а тоа значи дека нема да има негативни вредности или поголеми вредности од 1 кои негативно би влијаеле при комбинација со алгоритмот за оптимизација. Функцијата може да се диференцира и да обезбеди мазно приближување кон глобалниот минимум при пресметување на грешката. Оваа функција е најсоодветна бидејќи при симулација на хидроенергетскиот објект, сите вредности се во нормализирана форма во вредност од 0 до 1, па сигналот којшто се движи од средниот слој спрема слојот во којшто се наоѓаат излезите ќе има компактна форма во граница од 0 до 1. Исто така е многу битна бидејќи со sigmoid се обработуваат само две класи податоци, додека со другите слични се обработуваат повеќе класи едновремено.

Примената на tanh/tansig е најприсутна кај оние NN во кои имам присуство на повеќе слоеви. Оваа AF е многу слична со sigmoid AF, со иста форма на кривата, со единствена разлика во тоа што резултатите на излезот се менуваат од 1 до -1 како на Слика 18. Математички, tanh/tansig е претставена со равенка 26. Бидејќи излезите од оваа AF се центрирани во 0 (нула), многу е полесно да се префрли сигналот во наредниот слој во којшто треба повторно да се тренира мрежата или да се прилагодуваат вредностите на големината на сигналот.

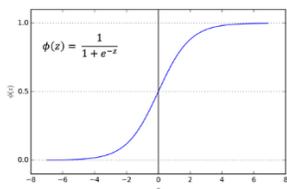
Во крајниот слој најчесто се поставува linear или relu AF која не ги активира сите неврони во исто време, туку само оние кои имаат поголема вредност од нула, додека тие што имаат вредност нула или негативна вредности, ќе бидат деактивирани. Бидејќи во предвид не се зимаат сите неврони туку само одреден број од нив кои немаат вредност 0, пресметковната ефикасност е многу поголема за разлика од tansig или sigmoid AF [86], [87], [88]. Математичката репрезентација на relu AF е претставена со равенка бр. 27.

$$f(x) = \frac{1}{1 + e^{-x}} \text{ sigmoid} \quad (25)$$

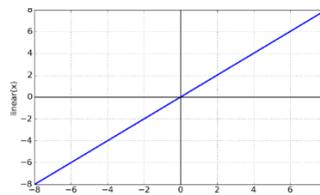
$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \text{ tansig/tanh} \quad (26)$$

$$f(x) = \max(0, x) = \begin{cases} x_i, & x_i \geq 0 \\ 0, & x_i < 0 \end{cases} \text{ relu} \quad (27)$$

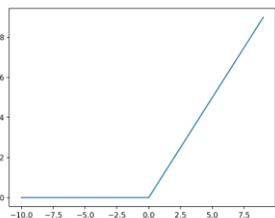
Сликовит приказ на секоја од користените AF.



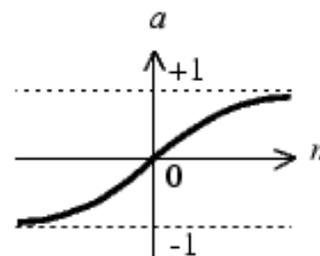
Слика 15. Sigmoid AF [80]



Слика 16. Linear AF [80]



Слика 17. ReLU AF



Слика 18. Tansig AF [89]

Освен изборот на бројот на неврони, бројот на слоеви, типот на AF, изборот на соодветна функција за пресметка на грешка е исто така многу битна бидејќи од тоа зависи колку точно се пресметува дизајнираниот модел, односно мрежата.

Постојат неколку пристапи за пресметка на грешката, доколку податоците што се обработуваат спаѓаат под класата на регресија, а тоа се пресметува преку апсолутна квадратна грешка, средна апсолутна грешка, пресметка според метода на Хубер. Доколку

се разработува модел кој припаѓа на класата на класификација или други поделби од делот кое го опфаќа ML, во тој случај се применуваат други методи за пресметка на грешката, односно на друг начин се одредува точноста на дизајнираниот модел.

Во однос на грешката според која ќе се анализираат добиените резултати, ќе се користи методата преку пресметка на апсолутна квадратна грешка, математички опишана со равенката бр. 28. Оваа метода е најчесто користена бидејќи секогаш се добива квадратот од резултатот, а тоа значи дека никогаш нема да има негативно решение. Исто така битно е дека со користење на оваа метода, при пресметка ќе се добива секогаш само еден локален минимум.

$$MSE = \frac{1}{z} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (28)$$

Во оваа равенка, z го означува бројот на измерени точки, y_i е вистинска вредност од податочното множество, додека \hat{y}_i е предвидената вредност, односно вредност што е добиена како резултат на движењето на сигналот во повратната патека.

При добивањето на резултатите, за најсоодветна комбинација на параметри на излез од NN се сметаат они кои ќе имаат најмала квадратна грешка.

Во однос на дефинирање на бројот на епохи, како дел од хиперпараметрите, постои едно непишано правило, а тоа е дека бројот на епохи се одредува во зависност од бројот на колони кои се дефинираат преку достапната база на податоци со која се дизајнира NN. Правилото гласи дека бројот на епохи треба да биде три пати поголем по бројот на колони кои го содржат податочното множество со кое се проектира NN. Но тоа правило не е секогаш најсоодветно и понекогаш не дава најдобри резултати [90][91] [43]. Најчесто најдобрата комбинација на параметри кои не се подложни на пресметка туку едноставно е потребно да се изберат согласно големината на податочното множество согласно искуството, но и согласно познавањето на проблемот којшто се разработува. Користењето на гореспоменатото правило може само да помогне при првичниот избор на епохи, но потоа изборот на вредноста на овој хиперпараметар е подложена на мануелно прилагодување. Овој параметар е исто така битен како на пример изборот на алгоритам за оптимизација или брзината на учење, но сепак со одредена мера може да влијае на резултатите кои би се добиле. Инаку во ML, епоха е еден целосен циклус на поминување на податочното множество низ алгоритамот за оптимизација. Колку пати податочното множество ќе помине низ алгоритамот за оптимизација на процесот.

Преку брзината на учење се одредува големината на сигналот на невронската мрежа, а воедно ги прилагодува/ажурира големините на сигналот за време на процесот на тренирање на самата мрежа. Брзината на учење е многу битна во процесот на брзината со која учи мрежата [92]. Брзината на учење најчесто најпрво се поставува да биде од 0,01 или 0,1, па се до максималното ниво односно 1. Брзината на учење никогаш не се поставува повеќе од 1, но исто така никогаш не се поставува помалку од 10^{-6} . Во почетен момент секогаш се

почнува прво од најмалата можна вредност, па доколку резултатите после тренирањето на мрежата не се соодветни, се зголемува вредноста на брзината на учење. Согласно истражувањата и резултатите во [93], најголема точност со најмала грешка во одредувањето на резултатите се постигнува со што е можно помала вредност на брзината на учење односно 0,0001 кое е приближно до 10^{-6} како минимална граница. Согласно равенките 29 и 30 се дефинира како коефициентот со којшто е дефинирана брзината на учење влијае на процесот на прилагодување на тежинскиот коефициент (weight) и коефициент на помест (bias), каде што со α е претставена брзината на учење.

$$w = w - \alpha \cdot \frac{\partial E}{\partial w} \quad (29)$$

$$b = b - \alpha \cdot \frac{\partial E}{\partial b} \quad (30)$$

Ако се следи сигналот на движење во NN, формулата за еден единствен неврон, а потоа и за подесување на големината на сигналот е согласно равенките 31 и 32. Од равенката 31, со a_k^l е дефиниран еден неврон во l -тиот слој од NN, додека σ е AF, тежинскиот коефициент (weight) - w_k^l , додека b_k^l е коефициент на помест (bias) во NN.

$$a_k^l = \sigma(z_k^l) \quad (31)$$

$$z_k^l = w_{k1}^l \cdot a_1^{l-1} + w_{k2}^l \cdot a_2^{l-1} + \dots + w_{kn}^l \cdot a_n^{l-1} + b_k^l \quad (32)$$

За да се ажурира т.е. да се прилагоди еден тежински коефициент потребно е да се пресмета парцијалниот изводот на грешката во однос на соодветната големина на сигналот како што е претставено математички со израз бр. 33 и 34.

$$\frac{\partial E}{\partial w_k^l} \quad (33)$$

$$\frac{\partial E}{\partial w_k^l} = \frac{\partial E}{\partial z_k^l} \cdot \frac{\partial z_k^l}{\partial w_k^l} = \frac{\partial E}{\partial a_k^l} \cdot \frac{\partial a_k^l}{\partial z_k^l} \cdot \frac{\partial z_k^l}{\partial w_k^l} \quad (34)$$

Со пресметка на парцијалните изводите на грешката во однос на тежинскиот коефициент, на крај се добива дека ажурирањето на тежинскиот коефициент се сведува на равенка 29, додека ажурирањето на подобрувачкиот коефициент се сведува на равенка 30. Освен постоечката равенка, подобрувачкиот коефициент во голем број од случаите се прилагодува да остане со вредност 1 (еден) во текот на целото време на тренирање на NN.

За да може да се спроведе тренирањето, валидацијата, но и ажурирањето на NN, потребно е да биде избран соодветен алгоритамот за оптимизација на процесот. Целта на алгоритамот за оптимизација е брзо конвергирање кон минимум. Тоа значи дека колку побрзо функцијата конвергира кон локален минимум толку побрзо е постигната стабилна состојба со најмала грешка. Користените алгоритми за оптимизација кои може да се најдат во оваа истражување се Levenberg-Marquardt (LMA) и Adam optimizer – ADAM. Согласно прегледаната и достапна литература, наведените алгоритми овозможуваат најбрзо конвергирање кон минимум [94][95], [81], [82], [96]. На Слика 91 и Слика 92 е прикажана

причината за примена на ADAM оптимизатор за пропрагирање кон глобален минимум и постигнување на најоптимално решение на излез од NN.

LMA алгоритмот за оптимизација се користи за постигнување на подобрени динамички карактеристики на хидроенергетскиот објект при управување со фреквенцијата додека ADAM оптимизаторот се користи кога е потребно да се одредат коефициентите за PID управувањето преку кои треба да се постигне поголема ефикасност во системот, но и подобрени динамички карактеристики.

ADAM оптимизаторот како најефикасен и најкористен, неговото дејство може да се подели на неколку фази во влијанието при добивање на најповолно решение и тоа, подготвување на алгоритмот, ажурирање на тежинскиот коефициент, отпочнување на фаза на корекција на подобрувачкиот коефициент и анализа на фазата на конвергенција кон оптималното решение [95].

Во првата фаза, односно подготвување на алгоритмот за користење, најпрво е потребно да се избере функција $f(\Theta)$, каде што Θ_0 е почетниот вектор, односно вредноста на тежинскиот коефициент и коефициентот на помест, соодветно. Согласно избраната, односно подготвената функција, потребно е да се изберат и постават соодветни вредности за следните параметри: α е брзина на учење (хиперпараметар), експоненцијалните стапки β_1 и β_2 кои се важни во процесот на конвергирање при ажурирање на градиентот и квадратот на градиентот, исто така се нарекуваат и параметри за измазнување на кривата на конвергирање. Исто така тука се спомнува и големина на чекор (step size) кој е правопропорционално зависна од брзината на учење и големина на градиентот $ss = \alpha \cdot g_t$. Тоа е поврзано со вистинското растојание при движење на параметрите во дефинираниот простор за време на процесот на ажурирање на коефициентите. Движечки просек (Moving average - MA) од вредностите на претходните градиенти (first moment estimation) се означува со m_t , додека просекот од квадратот на претходните градиенти (second moment estimation) се означува со v_t , дефинирање на временскиот пресметковен чекор - t [95], [97]. Вредностите на градиентот и квадратот на градиентот се означуваат со g_t и g_t^2 .

$$t \leftarrow t + 1 \quad (35)$$

$$m_t \leftarrow \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t \quad (36)$$

$$v_t \leftarrow \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2 \quad (37)$$

$$m_t \leftarrow m_t / (1 - \beta_1^t) \quad (38)$$

$$v_t \leftarrow v_t / (1 - \beta_2^t) \quad (39)$$

$$\Theta_t \leftarrow \Theta_{t-1} - \alpha \cdot m_t / \left(\sqrt{v_t + \epsilon} \right) \quad (40)$$

Равенка 36 го опишува ажурирањето на коефициентот на помест (bias) и тежинскиот коефициент (w) во првиот момент на проценка при фаза на конвергирање. Равенка 37 го опишува ажурирањето на коефициентот на помест (bias) и тежинскиот коефициент (w) во

вториот момент на проценка при фаза на конвергирање. Равенка 38 ја објаснува корекцијата на коефициентот на помест (bias) и тежинскиот коефициент (w) при претходната пресметка од првиот момент на проценка. Равенка 39 ја објаснува корекцијата на коефициентот на помест (bias) и тежинскиот коефициент (w) во вториот момент на проценка во фаза на конвергирање. Равенка 40 го опишува ажурирањето на коефициентот на помест и тежинскиот коефициент засебно за секое следно пресметување, како што веќе беше напоменато, земајќи ги во предвид претходните вредности на коефициентите.

Со повторување на редоследот на равенки 35 до 40 при процесот на пресметка, но и со промена на редоследот на пресметување, доаѓа до изнаоѓање на најповолното, најоптималното решение со користење на ADAM оптимизаторот во процесот на конвергирање на решението. Бидејќи α е брзина на учење во основна форма и има непроменлива вредност бидејќи е хиперпараметар, α_t е ефективна брзина на учење во точно дефинирано време t. Ефективната брзина на учење се менува во зависност од вредностите на претходните градиенти за која било направена пресметка. Ефективната брзина на учење се менува во зависност од времето и во зависност од параметерите (тежинскиот коефициент и коефициентот на помест). ADAM оптимизаторот ја прилагодува брзината на учење за секој параметар засебно врз основа на вредноста на претходните градиенти. Доколку кај вредностите на градиентите се појавуваат големи разлики, \hat{v}_t ќе има голема вредност, а α_t ќе се намали. Доколку кај вредностите на градиентите се појавуваат мали разлики, α_t ќе се доближи до вредноста на α . Ваквата карактеристика му помага на ADAM оптимизаторот да овозможи побрзо и посигурно конвергирање. За таа цел потребно е да се замени α со α_t и тоа на следниот начин, како што е прикажано со равенките 41 и 42:

$$\alpha_t = \alpha \cdot \sqrt{1 - \beta_2^t} / (1 - \beta_1^t) \quad (41)$$

$$\Theta_t \leftarrow \Theta_{t-1} - \alpha_t \cdot m_t / (\sqrt{v_t} + \hat{e}) \quad (42)$$

Согласно равенка 41, во $\sqrt{1 - \beta_1^t}$ се прави корекција на движечкиот просек на квадратот на градиентот, додека во $1 - \beta_2^t$ се прави корекција на движечкиот просек на градиентот. Потоа со равенка 42 е прикажан начинот на ажурирање на коефициентот на помест и тежинскиот коефициент засебно земајќи ја во предвид ефективната/променлива брзина на учење.

ADAM оптимизаторот функционира на тој начин што, се додека Θ_t не конвергира до оптимално, најдобро решение, постојано се повторува по брзината на ажурирање на коефициентот на помест (bias), пресметка и нивна корекција.

Во втора фаза се воспоставува правило за ажурирање на вредности на параметрите со користење на ADAM оптимизатор.

Многу важен параметар во воспоставувањето на правилото за ажурирање на вредностите е внимателно одбрана брзина на учење. Ефективниот чекор претставен во временски домен t

е $\Delta_t = \alpha \cdot m_t / \sqrt{v_t}$. Ефективниот чекор на пресметување има две гранични вредности кои се претставен на следниот начин согласно равенките 43, 44, 45:

$$|\Delta_t| \leq \alpha \cdot (1 - \beta_1) / \sqrt{1 - \beta_2} \quad (43)$$

во случај кога

$$(1 - \beta_1) > \sqrt{1 - \beta_2} \quad (44)$$

и втората гранична вредност.

$$|\Delta_t| \leq \alpha \quad (45)$$

Првиот случај, односно равенките 43 и 44 се присутни само во најтешки ситуации, а тоа е кога градиентот е нула во сите временски чекори на пресметување освен во моменталниот чекор на пресметување. Но за помалку комплицирани ситуации, ефективниот временски чекор, ќе биде помал од нула. Кога $(1 - \beta_1) = \sqrt{1 - \beta_2}$, тогаш $|m_t / \sqrt{v_t}| < 1$ во тој случај $|\Delta_t| \leq \alpha$. Во многу почести ситуации, ќе важи дека $m_t / \sqrt{v_t} \approx \pm 1$.

Ефективната големина на временскиот чекор во временски домен се приближно ограничени и тоа $|\Delta_t| \lesssim \alpha$. Овој израз може да се запише и разбере како безбедна зона околу која моменталниот градиент нема да произведува дополнителни и непотребни информации за пресметковниот модел.

Во третата фаза се прави корекција на коефициентот на помест (bias). Бидејќи експоненцијалната стапка β_1 е аналогна, поголемо внимание е потребно да се обрати на β_2 . Ако g е градиент на било кој стохастички објект f и доколку е потребно да се направи проценка на β_2 , во почетен момент се задава $v_0 = 0$, а притоа треба да се нагласи дека најпрво е потребно да се ажурира временскиот чекор t така што ќе важи изразот $v_t = \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t^2$, а овој израз понатаму може да се запише како функција од сите градиенти во сите претходни временски чекори, како што е претставено со равенка 46.

$$v_t = (1 - \beta_2) \sum_{i=1}^t \beta_2^{t-i} \cdot g_i^2 \quad (46)$$

Сепак е потребно да се знае како $E[v_t]$ математички е поврзан со $E[g_t^2]$ и каква е зависноста на промената на параметрите со менување на тие вредности.

Ако равенката 46 е појдовна точка, во тој случај се спроведува следната математика од лева и десна страна на равенката 46 и тоа на следниот начин:

$$E[v_t] = E\left[(1-\beta_2) \sum_{i=1}^t \beta_2^{t-i} \cdot g_i^2\right] \quad (47)$$

$$= E[g_t^2] \cdot (1-\beta_2) \sum_{i=1}^t \beta_2^{t-i} + \zeta \quad (48)$$

$$= E[g_t^2] \cdot (1-\beta_2^t) + \zeta \quad (49)$$

каде што $\zeta = 0$ доколку $E[g_t^2]$ има стабилна вредност, во спротивно ζ ќе има мала вредност.

Во четвртата фаза се изведува процесот на конвергирање, при што е важно да се предвиди параметарот Θ_t , а предвидената вредност да се имплементира како параметар од кој што на крај зависи квалитетот на излезниот резултат, f_t . Ако постојат конвексни кост функции, односно параметар кој покажува колку добро моделот на којшто се применува ML се совпаѓа со дефинираното податочно множество, $f_1(\Theta), f_2(\Theta), \dots, f_T(\Theta)$, вредноста односно влијанието на низата однапред не е познато. На тој начин се применува следниот израз за пресметка на вредноста на конвергирање, согласно равенка 50.

$$R(T) = \sum_{t=1}^T [f_t(\Theta_t) - f_t(\Theta^*)] \quad (50)$$

Согласно равенка 50, $f_t(\Theta_t)$ е предвидена вредност, а $f_t(\Theta^*)$ е најдобрата фиксна вредност која се зема во предвид при одредување на вредноста на конвергирање кон оптималното решение.

Откако ќе бидат избрани сите хиперпараметри, но и соодветен алгоритам за оптимизација, потребно е податочното множество што се внесува во NN да биде поделено на податоци со кои ќе се прави тестирање, валидирање и тренирање на мрежата. Најчесто не се зимаат сите три типа на податоци во предвид при проектирање на мрежата, туку се избира комбинација само од валидирање и тренирање на податоците. За валидирање на резултатите најчесто се издвојуваат 10% од вкупното податочно множество, а преостанатите 90% се користат за тренирање на NN. Оваа поделеност може да биде 20/80, но најчесто поделбата е 10/90. Понекогаш поделеноста може да се најде како 70 % тренирање, 15% валидирање и 15% тестирање на податоците. Во процесот на развој на модел врз кој ќе се применуваат методите и алгоритмите на ML, тренирање, тестирање и валидирање на користените податочни множества се употребуваат/применуваат за сосема различни цели и во различни фази во процесот на утврдување дали моделот работи со добри перформанси или навлегува во фаза на недоволно вклопување со моделот (underfitting) или преголемо вклопување со моделот (overfitting). Целта на процесот на тренирање е да го научи моделот да следи патерни и зависности помеѓу податоците во дефинираното множество. Исто така важен процес е да се минимизира грешката во податочното множество одделено за тренирање на моделот предум соодветно прилагодување на параметрите на моделот како што се коефициентот на помест и тежинскиот коефициент на NN. Податочното множество одвоено

за тренирање се користи на самиот почеток при процесот на развој на моделот. Моделот на којшто се работи, се доведува податочното множество кое се состои од влезни и излезни податоци. Моделот прави предвидувања преку пресметка на грешката помеѓу предвидената и вистинската вредност. Дел од параметрите кои може да се менуваат, преку користење на соодветен оптимизатор, се пресметуваат и адаптивно се менуваат. Валидацијата се користи за следење на перформансите на моделот за време на процесот на тренирање на моделот и учествува во процесот на промена на вредностите на параметрите кои се од големо значење за моделот и неговите излезни вредности, како што се коефициентот на помест и тежинскиот коефициент. Преку валидирањето се овозможува да се избегне *overfitting* и *underfitting*. Доколку се навлезе во едно од наведените ситуации, *overfitting* или *underfitting*, тоа е показател дека хиперпараметрите не се соодветно дефинирани во моделот, па потребно е истите да се променат. Откако ќе заврши процесот на тренирање и валидирање, се користи податочното множество за тестирање со цел да се одредат финалните перформанси на моделот. Преку тестирањето се добива проценка за тоа колку добро моделот ќе функционира со достапното податочното множество. Тестирање на моделот се прави откако ќе заврши процесот на тренирање и валидирање. Потоа, моделот е изложен на податочното множество кое досега не било искористено ниту при процесот на тренирање ниту при процесот на валидирање. Процесот на тестирање се извршува само еднаш и тоа после тренирањето и валидирањето. Разликите помеѓу тренирањето, валидирањето и тестирањето се претставени во Табела 3.

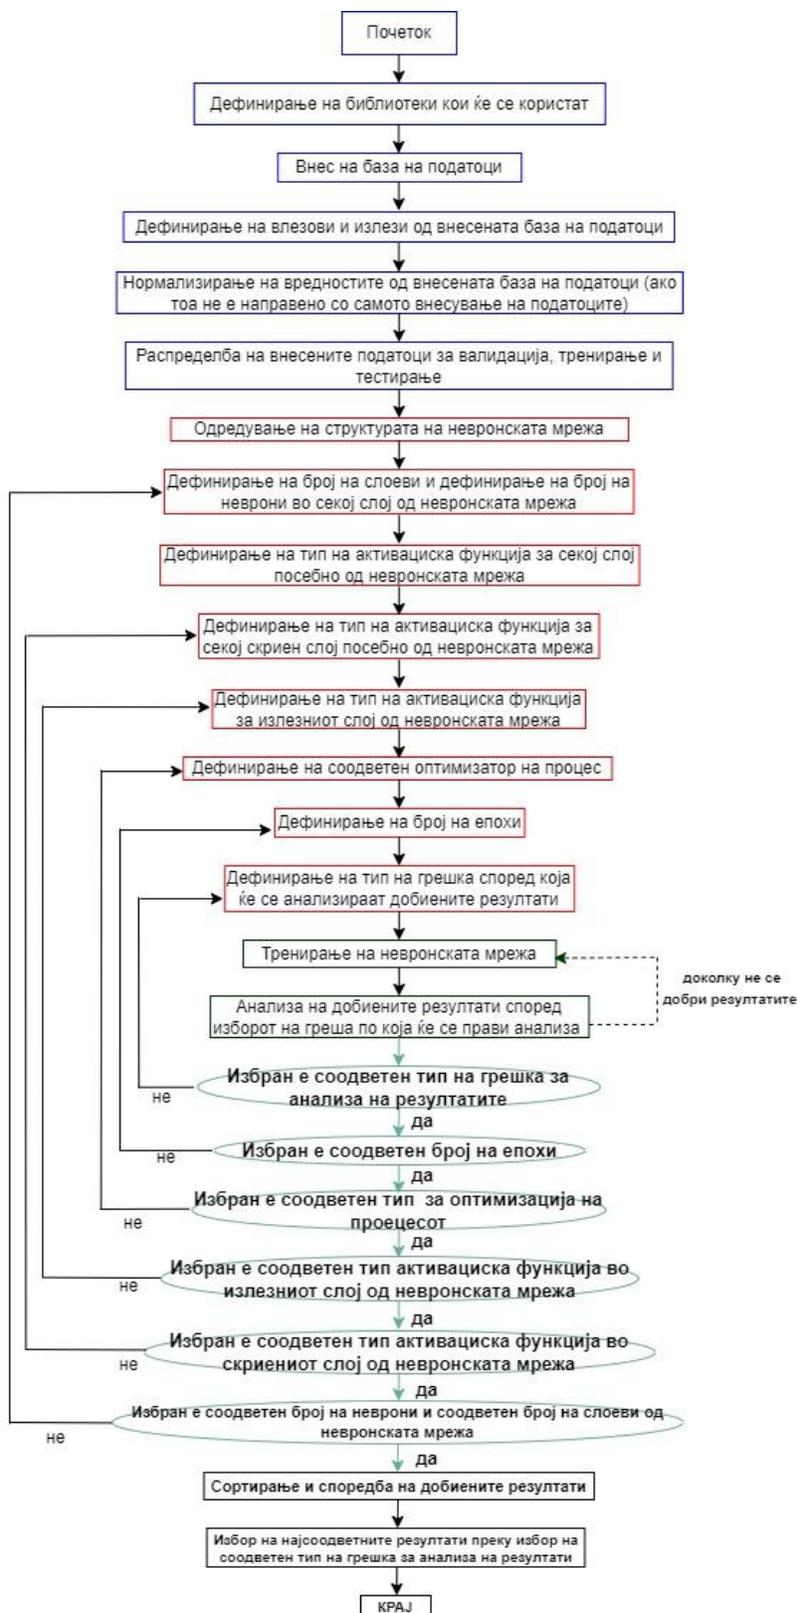
Табела 3. Разлика помеѓу тренирање, валидирање и тестирање на модел

Карактеристика	Тренирање	Валидирање	Тестирање
Причина за употреба	Учи патерни и зависности помеѓу параметрите во податочните множества	Учествува во процесот на промена на вредностите на параметрите и превенира <i>overfitting</i>	Ги оценува финалните перформанси на тренираниот и валидираниот модел
Кога се користи	На почетокот при развој на моделот	За време на процесот на тренирање	После процесот на тренирање и валидирање
Искористено податочно множество	Податочно множество за тренирање (најчесто со најголем процент – 70 до 80 %)	Податочно множество за валидирање (најчесто со иста застапеност како и множеството за тестирање – 10, 15 или 20 %)	Податочно множество за тестирање (најчесто со иста застапеност како и множеството за валидирање – 10, 15 или 20 %)
Кога се користи	Континуирано во текот на процесот на тренирање	За време на процесот на тренирање	Само еднаш на крајот од процесот на тренирање и валидирање

Цел поради која се применува	Да се минимизира грешката при тренирање на моделот	Да се оптимизираат хиперпараметрите на моделот	Мерење на финалните перформанси на моделот
-------------------------------------	--	--	--

Доколку по било која случајност, моделот навлезе во процес на учење од податочното множество предвидено за тестирање на моделот, крајните резултати ќе бидат нереални, грешни. Поради тоа е многу битно податочното множество предвидено за тестирање да остане недопрено се до самиот крај, односно се додека не заврши процесот на тренирање и валидирање.

Алгоритамот на проектирање на NN е претставен на Слика 19.



Слика 19. Алгоритам за дефинирање на код за пресметка на константи на PID управување со користење на машинско учење

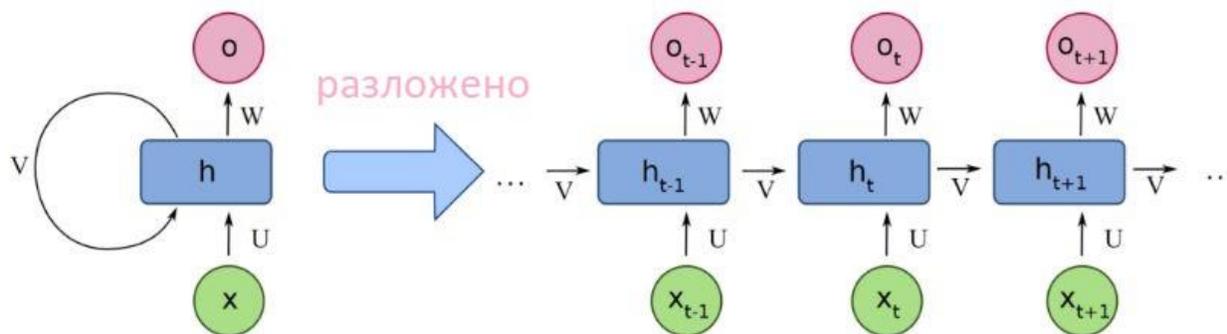
3.3 Идентификација на систем со примена на машинско учење

Со цел подобрување на динамичките карактеристики на еден хидроенергетски објект извршена е примена на методата на идентификација на систем преку примена на ANN и ML. Идентификација на систем со примена на ML во хидроенергетскиот објект е применета преку две методи. Метода на Рекурентни невронски мрежи (RNN), односно мрежи со можност на задржување на стара, но важна информација подолг временски период – долга краткорочна меморија или long short term memory (LSTM) и методата на повеќеслоен перцептрон - multilayer perceptron (MLP). MLP е од класата на ANN кои работат на принципот на движење на сигналот по паралелна на директната патека. Причината за користење на две сосема различни техники на примена на NN е поради сосема различниот начин на пресметка преку кое ќе може да се види процентуалната разлика во процесот на идентификација на системот, но и при подобрувањето на динамичките карактеристики на хидроенергетскиот објект.

3.3.1 Рекурентни невронски мрежи

Рекурентните невронски мрежи (RNN) се тип на мрежи кои се користат за моделирање и обработка на секвенцијални податоци кои се временски зависни [98], [99]

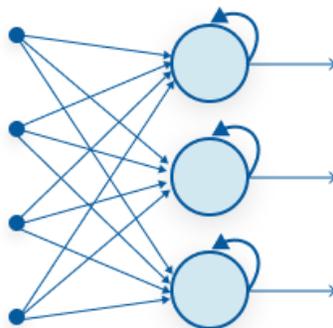
RNN работат на принцип на зачувување на излезот од соодветен слој и враќање на истиот во влезот од истиот слој со цел да се предвиди излезот од слојот со што е можно помала грешка. За време на изведување на пресметката внатре во NN, големината на јачината на сигналот останува непроменета за секој елемент посебно, како што е прикажано на Слика 20 [100].



Слика 20. Принцип на пренесување на сигнал преку RNN

RNN најчесто се опишува како мрежа која што е формирана од исти копии [100] како што е прикажано на Слика 20. Бројот на копии зависи од проектантот на мрежата и потребите за обработка на податоци.

Особено важна карактеристика на RNN е во тоа што со овој тип на NN се обезбедува континуирано однесување на настаните со присуство на сигнал којшто се однесува како повратна врска до соодветниот неврон како што е прикажано на Слика 20, додека со останатите типови NN како што се ANN кои работат на принципот на движење на сигналот по паралелна на директната патека, немаат континуитет во настаните и секој почеток на ново пресметување значи учење на мрежата од ново.



Слика 21. Движење на сигнал во RNN

Согласно ознаките на Слика 20, влезот во NN дефиниран во временски домен најчесто се означува со x_t , додека состојбата во слоевите се опишува со h_t . Излезот од NN во временски домен е означен со o_t . Подобрувањето на сигналот на мрежата се постигнува со воведување на параметрите V, U, W . Сигналот од претходниот слој е означен во V , со U и W се означени јачината на сигналот којшто пропагира низ NN од влезот кон нејзиниот излез.

Секој скриен слој е функција од два параметри и тоа x_t и h_{t-1} . Излезот од скриениот слој е во функција од h_t во време t , како што е прикажано со изразите 51 и 52.

$$h_t = f_h(x_t, h_{t-1}) \quad (51)$$

$$y_t = f_o(h_t) \quad (52)$$

Влезот, излезот и состојбата во секој скриен слој, математички е опишана со следните равенки 53 и 54:

$$h_t = f_h(x_t, h_{t-1}) = \Phi_h(W_{xh}^T \cdot x_t + W_{hh}^T \cdot h_{t-1} + b_h) \quad (53)$$

$$y_t = f_o(h_t) = \Phi_o(W_{yh}^T \cdot h_t + b_y) \quad (54)$$

Состојбата во секој скриен слој и во секој временски чекор се користи за да се долови значењето, поврзаноста и зависностите на податоците. Тоа значење се пренесува од еден временски чекор на следниот, дозволувајќи и на RNN да ги обработува податоците на начин зависен од времето. Тоа е она што ML овозможува на RNN, да ја следи патеката и зависноста во податоците што опфаќаат повеќе временски чекори.

Во скриените слоеви во кои сигналот преминува од една во друга состојба, Φ_h е нелинеарна AF, пример sigmoid или tanh. Потоа тежинскиот коефициент (weight) се множи со влезот во слојот x_t . На тој производ потоа се додава влезот којшто е претходно помножен со засилувачот на сигналот од претходниот слој. Φ_o е нелинеарна AF како на пример softmax или relu. Овој сигнал понатаму се множи со коефициентот за зголемување на

јачината на сигналот на излезот од скриениот слој h_t на кој пак сигнал на крајот се додава и коефициент на помест (bias) со цел подобрување на излезниот сигнал од RNN [101].

Најефикасните типови на RNN се LSTM и networks based on the gated recurrent unit (GRU). Во ова истражување ќе се прикаже влијанието на NN засновани на LSTM како дел од RNN.

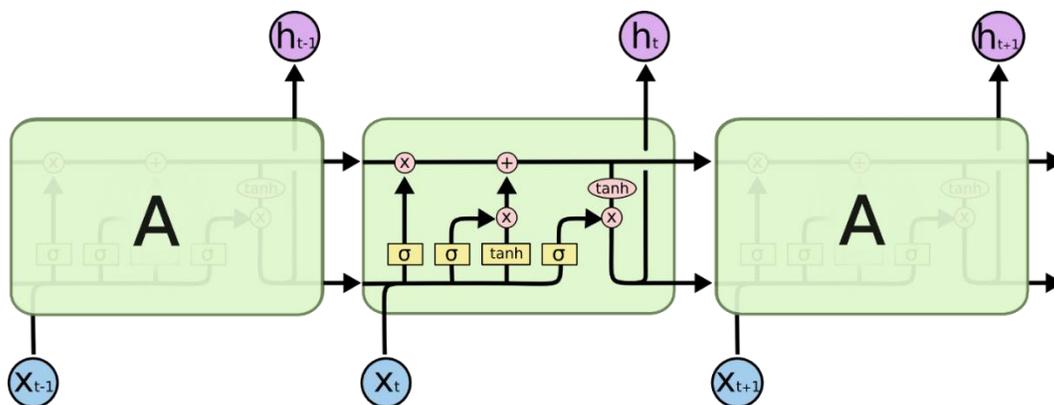
3.3.2 Невронска мрежа со можност за задржување на стара но важна информација подолг временски период – долга краткорочна меморија – LSTM

LSTM како дел од RNN се методи на длабокото учење кои се развиени со цел да се решаваат предизвиците поврзани со RNN. Како што е прикажано на Слика 20, NN заснована на LSTM има сопствена повратна врска околу самата ќелија. Таа сопствена повратна врска помага во процесот на памтење на претходните информации. Паметењето на информациите е во краток временски период или пак долготрајно, во зависност од јачината на сигналите и податоците. Од истата зависност самиот алгоритам селективно брише дел од информациите од неговата меморија [102][103] [54].

Информацијата движејќи се од влезот наспрема излезот од неврнот или ќелијата е заснована на неколку важни претходни и моментални состојби и тоа: состојба на претходна ќелија или неврн, состојба на претходен скриен слој, состојба на моментален влез од NN [103].

Архитектурата на NN заснована на LSTM е составена од различни блокови кои ја прикажуваат меморијата на ќелиите поединечно. LSTM во својата структура има и мемориски блок и токму тој блок ги меморира и манипулира со информациите. Манипулацијата со информациите од меморијата во ќелиите се прави со користење на три порти и тоа: влезна порта, излезна порта и таканаречена порта за заборавање на помалку важни или искористени информации претходно од мрежата [98], [100], [101], [102], [103].

Главната форма и структура на LSTM архитектурата е прикажана на Слика 22.



Слика 22. Архитектура на моделот LSTM [103]

Согласно Слика 22 и претходно дефинираните порти, секоја од нив има соодветно значење и тоа:

1. Порта за заборавање на помалку битни или искористени информации – Forget gate – ова е прва порта и е означена со (σ). Преку оваа порта се бришат информациите што не се релевантни од претходните ќелии во мрежата. Преку оваа порта во самиот алгоритам односно во самата NN се внесуваат различни типови на филтри и оптимизатори од кои секако зависат перформансите на самата мрежа. Во оваа порта се среќаваат два типа на влез и тоа h_{t-1} и x_t . h_{t-1} е скриената состојба во претходната ќелија, додека x_t е влезот во временски домен. Влезовите дефинирани во мрежата се множат со коефициент којшто е во форма на матрица со соодветна големина, а после множењето на целиот израз се додава коефициент на помест (bias). Со цел активирање односно додавање динамика на целата конфигурација, се додава и sigmoid AF. Оваа AF се додава бидејќи излезите се генерираат во опсег од 0-1. Со помош на оваа функција се носи одлука кои вредности остануваат за понатамошно тренирање и обработка, а кои ќе се исфрлат како нефункционални и нерелевантни во понатамошниот тек на обработка на податоците со цел добивање најсоодветни излезни решенија [103].

2. Влезна порта

Влезната порта се поврзува на (+), а со тоа се поврзуваат σ (sigmoid) и \tanh AF. Со ова се додава информација во ќелијата за нејзината состојба, така што подоцна се воведува sigmoid AF со цел да се регулира големината на излезната вредност. На овој начин се формира вектор со соодветни вредности во зависност од претходните состојби. Овие вредности понатаму се додаваат во ќелијата со AF \tanh . Иста така ја множи вредноста добиена од sigmoid AF со векторот добиен од \tanh AF, а потоа додава информации за состојбата на ќелијата. Оваа долга постапка се прави со цел информациите спроведени низ ќелијата да се од голема важност за излезната информација од таа ќелија, но и да не бидат повторувачки, туку секој чекор да има единствена автентичност на спроведената информација [103].

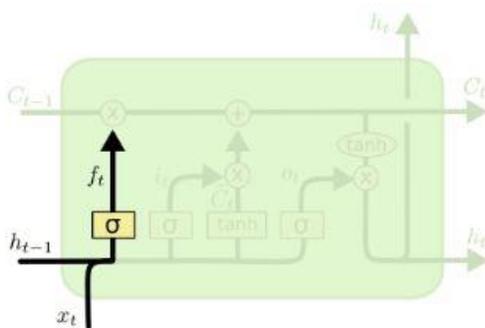
3. Излезна порта

Во излезната порта се селектираат важни информации за моменталната состојба на ќелијата и така се одлучува кој излез ќе биде зададен како решение на поставениот проблем. Преку излезната порта се формира вектор, а на тој начин се филтрираат и регулираат излезните вредности со користење на h_{t-1} и x_t . Формираниот вектор се множи со h_{t-1} и x_t и на тој начин се добива конечната филтрирана излезна вредност [103].

Математички гледано, чекор по чекор примената на NN заснована на LSTM во апликативни процеси е опишана преку следните записи.

Првиот чекор во примената на NN заснована на LSTM е да се донесе одлука која информација поминува, а која информација ќе биде исфрлена како непотребна или презаситена. Таа одлука се прави со користење на sigmoid AF во првата порта т.е. во портата

за заборавање на помалку битните или искористените информации. Се прави проверка на вредностите на h_{t-1} и x_t , а потоа се исфрла број со вредност помеѓу 0 и 1. Таа проверка се прави за секоја од вредноста којашто ќе биде дефинирана од мрежата во зависност од нејзината состојба C_t . Вредноста 1 значи дека информацијата е од голема важност и истата мора да се задржи додека вредност 0 значи дека таа информација мора да се отстрани бидејќи нема никакво влијание на излезната вредност. Во проблемот со користење на LSTM за подобрување на динамичките карактеристики на хидроенергетски објект е да се земе во предвид динамика на системот којашто е верифицирана и докажано применета и да се истренира системот да се прилагоди на таа постоечка и позната динамика, а потоа да се постигне и одредено подобрување на динамичките карактеристики на хидроенергетскиот објект. За таа цел потребно е незначајните информации и параметри да се исфрлат од состојбата на ќелијата, а да останат да дејствуваат само важните информации и параметри. Математички тоа се опишува на следниот начин:

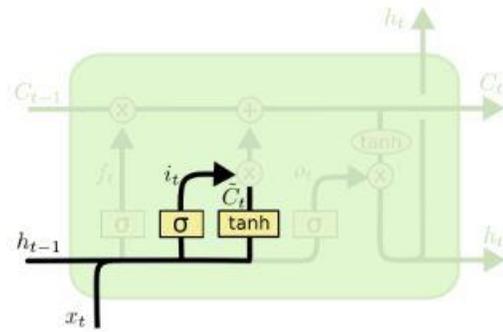


Слика 23. Состојба за одлука која информација останува, а која се исфрла како непотребна [98]

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (55)$$

Следната информација е да се донесе одлука која нова информација ќе се зачува во ќелијата. Првиот дел е поминување на информацијата преку sigmoid AF во влезната порта и потоа се носи одлука која информација поминува, а која ќе остане да влијае на состојбата на ќелијата. Следно, tanh AF формира вектор со нови вредности, \tilde{C}_t . Доколку тие вредности се важни, истите се додадени во состојбата на ќелијата.

Во однос на примената на оваа метода во подобрување на динамичките карактеристики на хидроенергетски објект, значи дека одредени вредности кои се генерираат, а истите го нарушуваат подобрувањето, да бидат исфрлени од употреба.



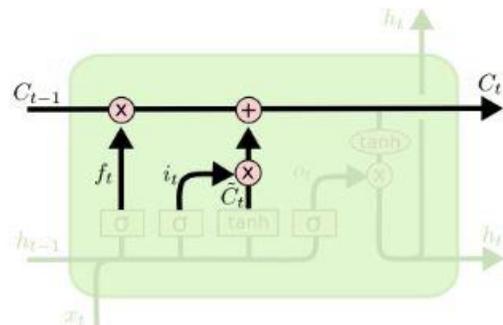
Слика 24. Состојба на формирање нови вектори со цел класифицирање на информацијата како важна или не важна [98]

Математички тоа се опишува на следниот начин:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (56)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (57)$$

После тој процес, следува време за ажурирање на состојбата на старите ќелии, C_{t-1} во C_t . Старата состојба на ќелијата се множи со f_t притоа елиминирајќи ги состојбите и параметрите кои претходно биле пропуштени како информација, а сепак немале толку големо значење во одредување на излезот. Потоа се додава $i_t \cdot \tilde{C}_t$. Со тоа се назначува додавање на нови вредности во пресметковниот модел и на тој начин се извршува ажурирање на информациите што се движат кон излезните параметри.



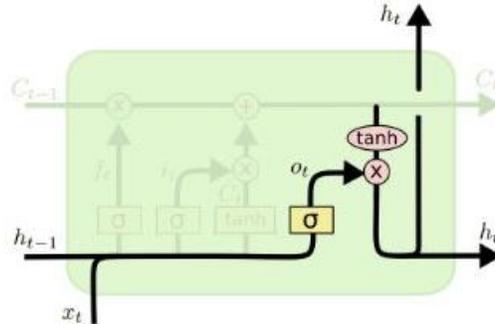
Слика 25. Состојба на ажурирање на состојбата во ќелиите [98]

Математички тоа се опишува на следниот начин:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (58)$$

Финалниот чекор е да се донесе одлука кои информации ќе се пласираат како излез со најголема ефикасност и важност. Излезната вредност ќе зависи од состојбата на ќелијата, но со филтрирани параметри. Тоа значи дека прво информацијата поминува низ ќелијата во која што е активна sigmoid AF и на тој начин се филтрираат сигналите, па се одлучува кој сигнал ќе се процесира понатаму во ќелијата, мора да биде со вредност од 0 до 1. Потоа таа информација поминува низ tanh AF којашто има вредност од -1 до 1 и од тука се множи

излезната вредност со вредноста на излез од sigmoid AF. Тоа значи дека во овој дел се носи одлука дали динамиката на системот е подобрена или влошена во зависност од споредбата на излезната матрица и добиената матрица која го поминала процесот на различни состојби на ќелиите.



Слика 26. Формирање на излезниот сигнал [98]

Математички тоа се опишува на следниот начин:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (59)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (60)$$

3.3.3 Алгоритам за дефинирање на дигитален близнак и методологија за идентификација на систем со невронска мрежа заснована на долга краткорочна меморија - LSTM

За да се моделира NN којашто е заснована на LSTM, потребно е да се дефинираат следните параметри.

1. Дефинирање на потребните библиотеки за да може да се извршува пресметката.
2. Дефинирање на влезите (податочни множества за влезови).
3. Дефинирање на целни излези (податочни множества за целни излези).
4. Се дефинира типот на NN со којашто ќе се обработуваат податоците.
5. Се дефинира бројот на скриени слоеви и бројот на неврони во секој од слоевите.
6. Се дефинира AF за секој од слоевите посебно.
7. Се дефинира типот на оптимизатор.
8. Се дефинира типот на грешка според која ќе се пресметува моделот.
9. Се тренира моделот.
10. Се дефинира бројот на полови и нули со цел да се генерира преносна функција.
11. Се дефинира горната и долната граница на половите и нулите од преносната функција.
12. Се вадат генерираните вредности за половите и нулите.
13. Се генерира модел во Simulink .
14. Се дефинира името и локацијата на генерираниот модел во Simulink.
15. Се дефинира името на блок дијаграмот од генерираниот модел во Simulink каде што треба да се запишат генерираните вредности.
16. Се дефинира код за пресметка на симулацијата во Simulink преку Python.

17. Се дефинира код за издвојување на излезните вредности за генерираната динамика на моделот.
18. Се споредуваат добиените излези со излезите од моделот пред да се примени ML преку MLP.

3.3.4 Повеќеслоен перцептрон - MLP

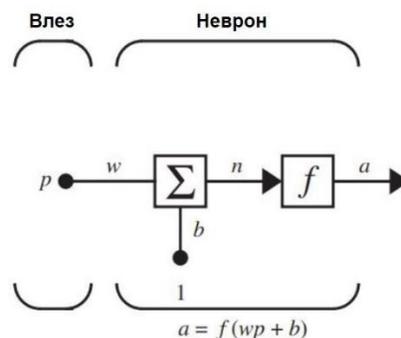
ANN се најчесто поврзувани со повеќеслојни перцептрони. Тие се еден од најчесто користените NN за обработка на податочни множества, не за да се креира реалистичен модел, туку за развој и градење на робустен алгоритам за да може истиот понатаму да се користи при моделирање за анализа на покомплицирани проблеми.

Комбинацијата од еден влезен слој, еден скриен слој и еден излезен слој го сочинуваат MLP. Доколку NN содржи повеќе од еден скриен слој тоа веќе се нарекува длабока NN или длабоко учење [104].

NN на MLP е составена од едноставни елементи. Тоа е неврон кој може да биде со еден влез или неврон со повеќе влезови. Независно од бројот на влезови, невроните понатаму се групираат во слоеви. Словите понатаму се групираат и на тој начин се гради мрежа од слоеви кои се составени од повеќе неврони [105]. Излезот од еден неврон се пресметува на начин прикажан со равенка 61 каде што p е скалар кој што помножен со скалар w , го формираат изразот $w \cdot p$. Излезот од невронот, a е исто така скалар. Функцијата врз основа на која се прават пресметките за да се добие вредноста на скаларот на излез од невронот, е дефинирана како AF односно f . Коефициентот на помест (bias) е означен со b .

$$a = f(w \cdot p + b) \quad (61)$$

Во текот на целиот процес на учење, w и b се параметри коишто постојано се менуваат. Нивното ажурирање во текот на процесот на учење зависи од чекорот на учење, од типот на оптимизаторот, AF кои се поставуваат на крајот од секој скриен слој и од излезниот слој. Наведените параметри го носат името хиперпараметрите поради тоа што имаат големо влијание врз излезните, финални резултати.



Слика 27. Единечен перцептрон прикажан во општа состојба [105]

AF на крај има улога да го претвори излезниот сигнал во соодветна форма со соодветни граници, а формата на излезниот сигнал зависи од типот на функцијата.

Кај овој тип на NN, сигналот патува од влезниот кон излезниот слој поминувајќи низ скриените слоеви. Бројот на скриени слоеви којшто може да се постави во мрежата е неограничен, а тоа зависи од податочното множество и од комплексноста на моделот којшто се анализира. Информацијата низ мрежата поминува по права рутина, а притоа во едно движење од влезот спрема излезот, сигналот никогаш не поминува низ истиот неврон два пати [106].

Овој тип на мрежи, каде што сигналот се движи од влезниот слој спрема излезниот без притоа во едно движење два пати да поминува низ ист слој и неврон, има мала способност во добивањето задоволителни резултати поради тоа што овој тип на NN нема меморија и податоците што ги прима еднаш на влез, после излезот од невронот нема зачувани траги од сигналот. Едноставно кај овој тип на мрежа, пресметката и ажурирањето на податоците внатре во мрежата се прави моментално и секогаш одново, а не врз база на претходно истренирани или запаметени сценарија согласно достапнатото податочно множество.

3.3.5 Алгоритам за дефинирање на дигитален близнак и методологија за идентификација на систем со невронска мрежа заснована на повеќеслоен перцептрон - MLP

За да се моделира NN којашто е заснована на MLP, потребно е да се дефинираат следните параметри.

1. Дефинирање на потребните библиотеки за да може да се извршува пресметката.
2. Дефинирање на влезовите (податочно множество за влезови).
3. Дефинирање на целни излези (податочно множество за целни излези).
4. Се дефинира типот на NN со којашто ќе се обработуваат податоците.
5. Се дефинира бројот на скриени слоеви и бројот на неврони во секој од слоевите.
6. Се дефинира AF за секој од слоевите посебно.
7. Се дефинира типот на оптимизатор.
8. Се тренира моделот.
9. Се дефинира бројот на полови и нули со цел да се генерира преносна функција.
10. Се дефинира горната и долната граница на половите и нулите од преносната функција.
11. Се вадат генерираните вредности за половите и нулите.
12. Се генерира модел во Simulink .
13. Се дефинира името и локацијата на генерираниот модел во Simulink.
14. Се дефинира името на блок дијаграмот од генерираниот модел во Simulink каде што треба да се запишат генерираните вредности.
15. Се дефинира код за пресметка на симулацијата во Simulink преку Python.
16. Се дефинира код за издвојување на излезните вредности за генерираната динамика на моделот.
17. Се споредуваат добиените излези со излезите од моделот пред да се примени ML преку MLP.

4 Глава 4 Симулација на модел при црн старт на хидроенергетски објект со користење на машинско учење и управување засновано на невронски мрежи

4.1 Вовед

Во Глава 3, беше дефиниран моделот на хидроенергетски објект кој опфаќа островска работа на хидраулична турбина. За ваквите модели изработени се симулации со цел да се анализираат статичките и динамичките карактеристики на хидроенергетскиот објект.

Законите за управување кои се искористени за анализа на карактеристиките на објектот се применуваат за управување со моќноста. Применети се неколку типови управување и тоа управување засновано на NN како и примена на ANN и ML со цел да се анализира нивното влијание и можноста за подобрување на статичките и динамичките карактеристики на објектот на управување.

Моделите кои се земени во предвид и врз кои ќе се прави испитување на влијанието за примена на управување засновано на NN и влијанието на ANN и ML при подобрување на управувачките карактеристики врз објектот на управување, се линеарниот и нелинеарниот модел при островска работа на хидроенергетски објект, претставени на Слика 2, Слика 3, Слика 4, Слика 5, Слика 6, Слика 28 и Слика 29. Кај овие модели не се земени во предвид влијанијата на водостанот, влијанијата на еластичните својства на водениот столб и притисниот цевковод.

Симулациските испитувања ќе се направат со помош на Simulink, како најпопуларна графичка средина за моделирање, симулирање и анализа на динамичките карактеристики на еден објект на управување.

Освен Simulink, ќе се користи и програмскиот јазик Python со цел да се изгради NN која понатаму ќе се тренира во зависност од податочното множество кое ќе биде внесено во мрежата, а преку која ќе може индиректно да се влијае врз подобрувањето на карактеристиките на објектот на управување.

Примената на ML во процесот на подобрување на управувачките карактеристики е индиректен бидејќи со помош на NN која што ќе се гради, а потоа и ќе се тренира, ќе се добиваат пропорционалната, интегралната и диференцијалната константа, а тие вредности ќе се запишуваат во PID управувањето којшто директно ќе биде вклучен во објектот на управување.

Главно што треба да се заклучи од оваа глава е како новите технологии засновани на ANN, без разлика дали станува збор за управување или чисто имплементација на ML, може да придонесат во подобрувањето на динамичките карактеристики на еден реален хидроенергетски објект, но и тестирање на примената на нови технологии во екстремни случаи кои може да бидат од голема важност поради можноста за оштетување на постројката.

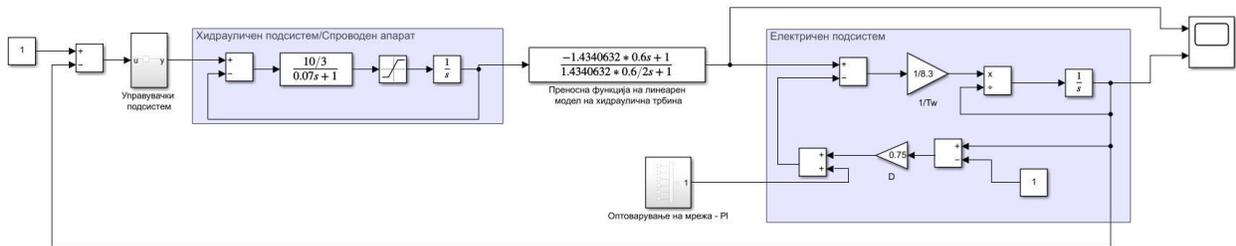
Согласно достапните модели [65] врз кои ќе се прават симулациите и испитувањата, во однос на стабилноста на системот, нема да се разгледува реактивната туку ќе се анализира само активната моќност.

Моделите кои ќе се користат за ова истражување се моделите во кои не се земени во предвид еластичните својства на водениот столб како и должината на цевководот бидејќи во [65] е докажано дека кај хидроенергетските објекти со краток доведен цевковод и среден пад, влијанието на еластичните својства на водениот столб и притисниот цевковод е занемарливо мало.

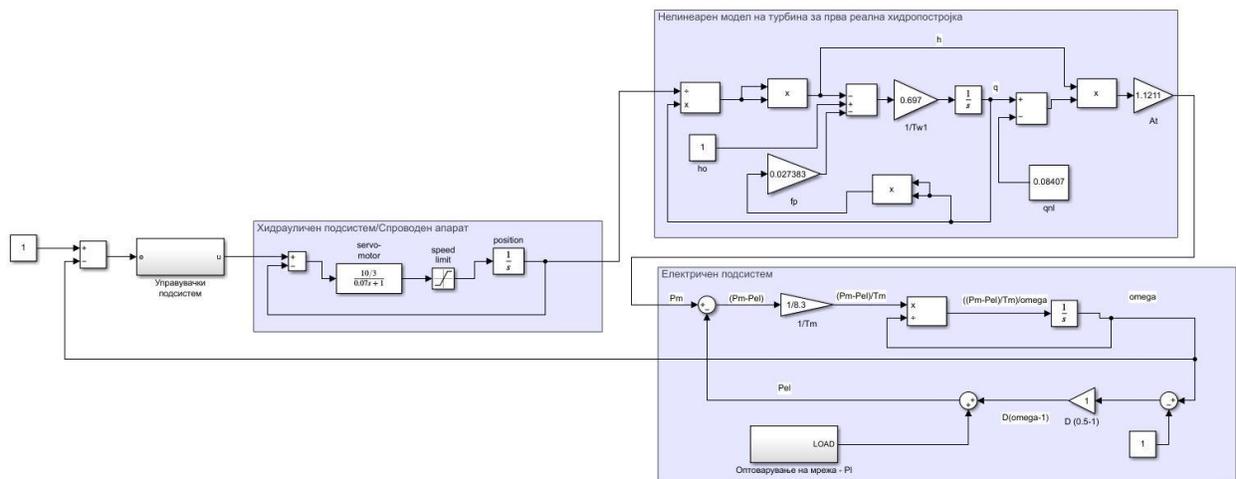
4.2 Изолирана работа на хидроенергетски објект

Во оваа глава ќе се анализираат резултатите од моделите изработени во Simulink, но и анализа на резултатите добиени со директна имплементација на ML во процесот на подобрување на карактеристиките на хидроенергетски објект .

За таа цел во ова поглавје ќе бидат претставени модели од линеарен (Слика 28) и нелинеарен модел (Слика 29) на хидраулична турбина како дел од управувачки објект, односно хидроенергетски објект изработен во Simulink.



Слика 28. Модел изработен во Simulink за хидроенергетски објект и ленеарен модел на хидраулична турбина [72]



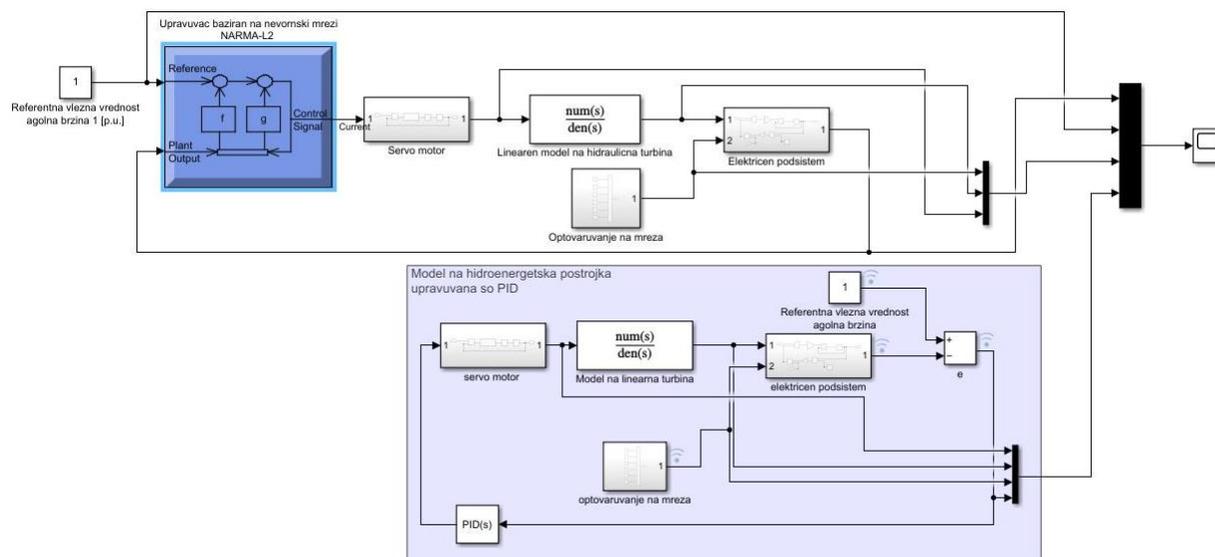
Слика 29. Модел изработен во Simulink за хидроенергетски објект и неленеарен модел на хидраулична турбина [72]

Најпрво ќе се анализираат одзивите и нивните карактеристики од моделите изработени во Simulink, а по нивна детална анализа, ќе се прикажат и анализираат резултатите добиени со користење на ML. Добиените резултати ќе се споредат со одзивите добиени и анализирани во [65].

4.3 Линеарен модел на хидроенергетски објект

При математичко моделирање на линеарна хидраулична турбина најголемо влијание има временската константа на водата, T_w чија што вредност во најголема мера зависи од должината и попречниот пресек на цевководот, протокот и притисокот, но и од моќноста на турбината согласно [68].

Како што во Глава 3 беше претходно прикажан блок дијаграмот на хидроенергетскиот објект преку Слика 1, на Слика 30 е прикажан симулацискиот модел на линеарна математичка репрезентација на хидраулична турбина од хидроенергетски објект во кој што се земени во предвид спроводниот апарат, хидрауличната турбина, електричниот потсистем, симулирано е и оптоварувањето на мрежа, а исто така како референтна вредност која што понатаму се управува и анализира е референтната аголна брзина чија вредност е 50 Hz, а нејзината нормализирана вредност е 1 р.и. Класичниот начин на управување на хидроенергетски објект е со примена на PID управување како наједноставно и најлесно применливо, но освен тоа постојат и други техники на управување со моќноста. Еден од тие начини е прикажан на Слика 30, а тоа е со примена на управување засновано на NN. Со примената на управување засновано на NN, во почетен момент не е земена во предвид дополнителна управувачка метода која би и помогнала на NN, туку едноставно се анализирани динамичките карактеристики на системот само доколку управувањето засновано на NN има влијание на системот. Влез во управувањето е референтна аголна брзина, а излез е управувачкиот сигнал којшто влегува во хидрауличниот потсистем. Грешката којашто ја прави системот е претставена со повратната врска која влегува во plant output. Начинот на пресметување на управувачкиот сигнал е опишан во Глава 3. Поради тоа што примената на техники од ML сами по себе побаруваат пресметка и избор на голем број параметри, при секоја итерација на пресметка најчесто се добиваат различни решенија.



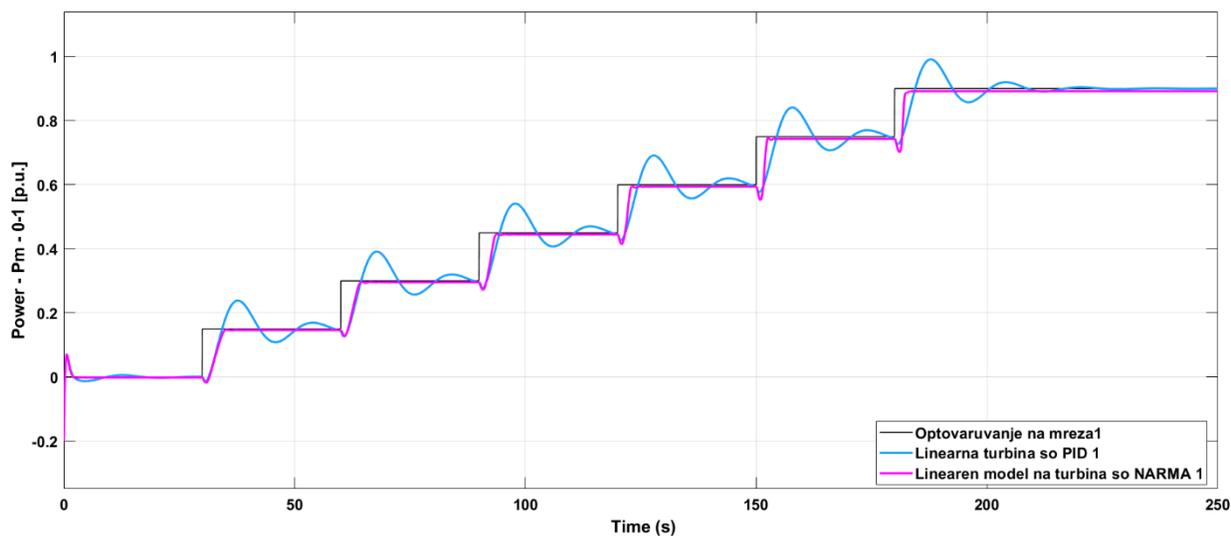
Слика 30. Линеарен модел на хидроенергетски објект со управување засновано на NN – NARMA во споредба со линеарен модел на хидроенергетски објект со управување само со PID

За да се добие одзивот прикажан на Слика 31, управувањето засновано на NN ги има следните карактеристики:

Табела 4. Параметри за мрежата од управување засновано на NN

Структура на мрежата	
Број на скриени слоеви	2
Период на семплирање	0.01 [s]
Тип на АФ	Tanh и Relu
Алгоритам за оптимизација	LMA
Податоци за тренирање на мрежата	
Број на податоци за тренирање	1000
Број на влезови во мрежата	1
Број на излези од мрежата	1
Број на епохи	100

Од Слика 31 може да се забележи дека согласно параметрите од Табела 4, одзивот за моќноста кој се презентира при црн старт на хидроенергетски објект е стабилен, но со еден недостаток, а тоа е дека генерираната моќност никогаш нема да ја постигне потребната побарана моќност. Тоа може да се примети од тоа дека одзивот со розева линија никогаш не го допира одзивот со црна линија која го означува оптоварувањето на мрежа. Тоа значи дека турбината никогаш нема да достигне толку моќност колку што е побарано односно нема да го произведе побараното количество електрична енергија. Од тука може да се каже дека самостојното дејствување на управувањето засновано на NN влијае како чисто пропорционално управување бидејќи во стационарна состојба прави грешка што не може да се отстрани [107].



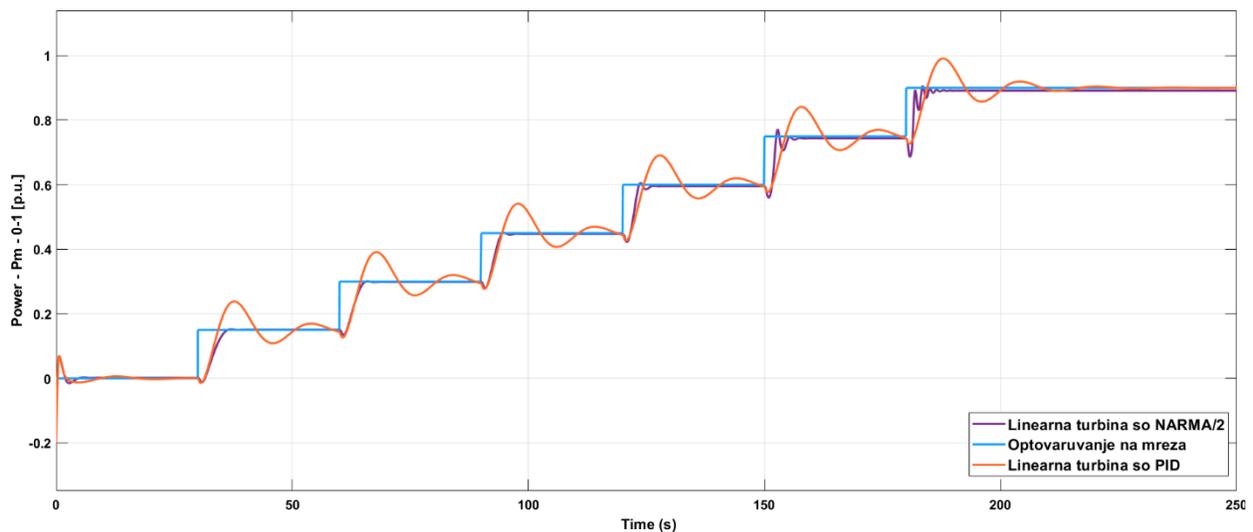
Слика 31. Споредба на одзиви за модел на линеарна турбина со NARMA управување и управување со PID

Одзивот претставен на Слика 32 е исто така добиен од линеарен модел на хидроенергетски објект, но со различни параметри за NARMA управување.

Табела 5. Параметри за мрежата од управувањето засновано на NN

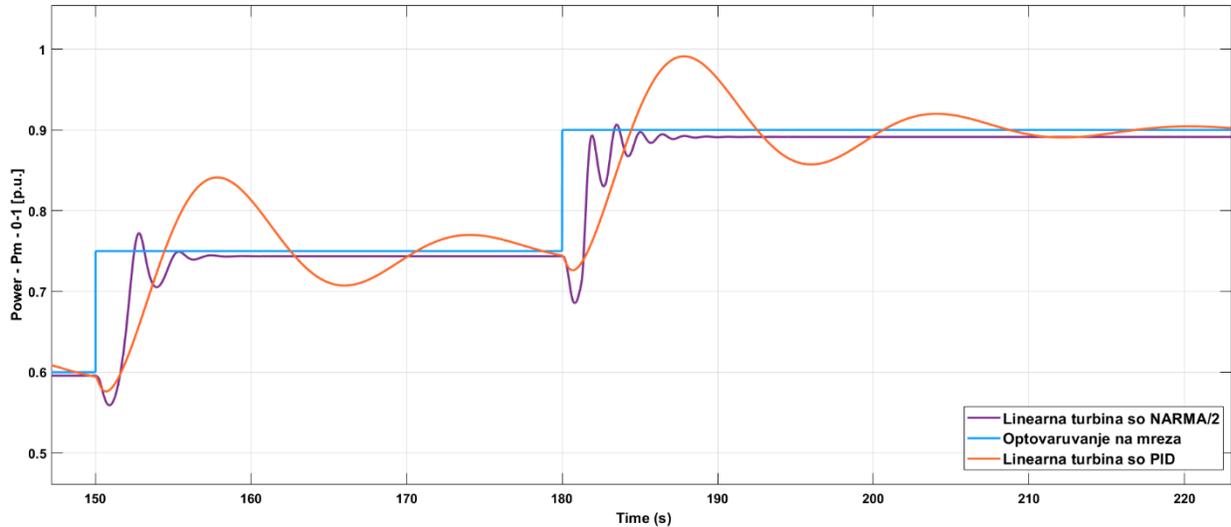
Структура на мрежата	
Број на скриени слоеви	2
Период на семплирање	0.1 [s]
Тип на АФ	Tanh и Relu
Алгоритам за оптимизација	LMA
Податоци за тренирање на мрежата	
Број на податоци за тренирање	1000
Број на влезови во мрежата	1
Број на излези од мрежата	1
Број на епохи	500

Согласно структурата на NN, брзина на учење и бројот на епохи се променети во споредба со одзивот претставен на Слика 31. На Слика 32 може да се забележи појава на мали осцилации кај одзивот на генерираната механичка моќност при приближување кон стационарна состојба. Иако во првите моменти на отпочнување со работа, турбината ја следи потребата за производство на електрична енергија, но во последните два чекори се забележува појава на грешка односно дека генерираната механичка моќност не ја следи потребата за побараната моќност. Објаснувањето е исто како и на Слика 31, дека NARMA управувањето се однесува како чисто пропорционален елемент без притоа да може да ја елиминира грешката во стационарна состојба.



Слика 32. Споредба на одзив од линеарен модел со примена на NARMA управување и PID управување

На Слика 33 е претставен детален поглед од последните два чекора при приближување кон стационарна состојба, каде што може да се види грешката која се појавува помеѓу потребата од генерирана механичка моќност, одзивот со сина линија и генерираната моќност, одзивот со портокалова линија (при управување со PID) и виолетовата линија (при управување со NARMA) [107].



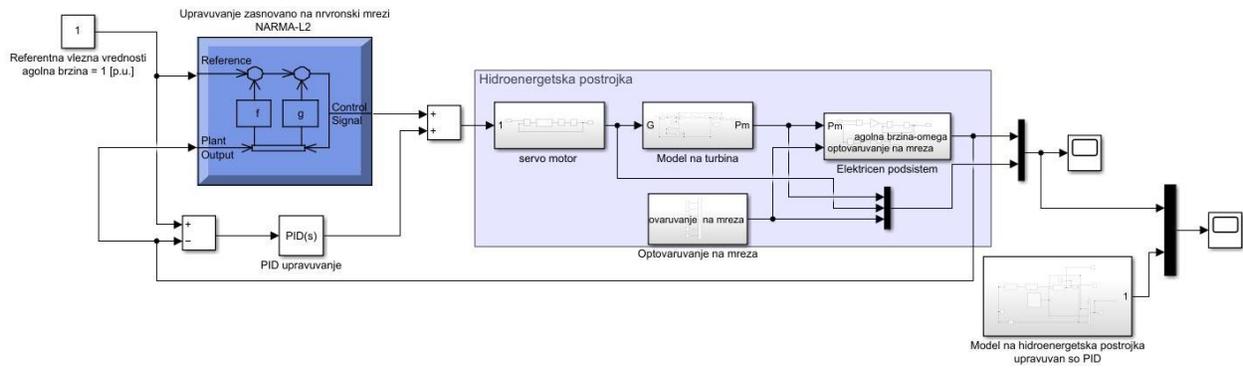
Слика 33. Детален поглед на одзив од линеарен модел управуван и трениран со примена на NARMA

4.4 Нелинеарен модел на хидроенергетски објект без водостан и без влијание на еластични својства на воден столб

При математичко моделирање на нелинеарна хидраулична турбина (прикажано во Глава 3 преку Слика 4 и Слика 29), освен временската константа на водата T_w , влијание имаат и други параметри како што се волуменските загуби низ турбината q_{nl} , коефициентот на засилување A_t и коефициент на загуби во цевководот ϕ_{fp} .

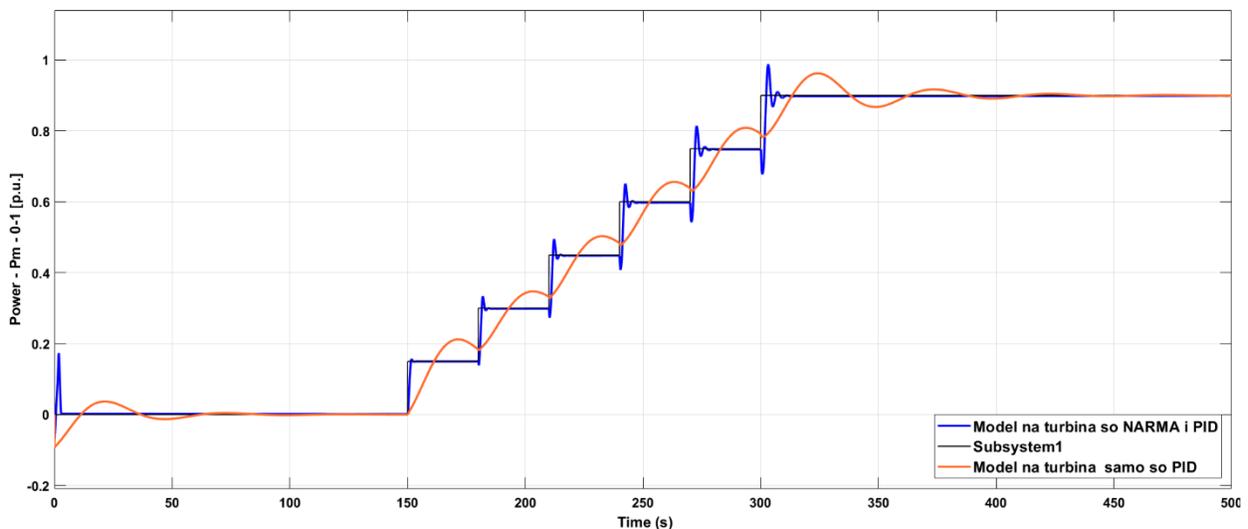
Од Слика 34 може да се види дека симулацискиот модел на хидроенергетски објект (споредба на два модели, еден модел каде што управувањето е со примена на невронски мрежи – NARMA во комбинација со PID, а вториот модел е само со управување со PID) ги опфаќа следните објекти и тоа спроводен апарат, хидраулична турбина заедно со загубите во цевководот опишана преку нелинеарни математички модели, електричниот потсистем и оптоварувањето на мрежа. Дополнително согласно симулацискиот модел (Слика 29), управувањето со фреквенцијата односно аголната брзина, е комбинација од управување засновано на NN и конвенционален тип управување, PID.

Комбинацијата на две методи на управување, поточно комбинирање два управувачки сигнали е земена во предвид за испитување на влијанието врз динамиката на управувачкиот објект. Како што беше претходно прикажано согласно резултатите од Слика 31, Слика 32 и Слика 33, примената само на управување засновано на NN кое треба да управува со аголната брзина на ротирање на вратилото на хидрауличната турбина воведува грешка во системот со тоа што механичката енергија што ќе треба да ја произведе турбината, нема да ја постигне потребната/побараната моќност. За таа цел на управувањето засновано на NN е додадено PID управување, како би можело да се отстрани минималната грешка во стационарна состојба. Неговата цел е да ML помогне на управувачкиот сигнал од невронската мрежа да ја елиминира грешката која се појавува пред постигнување на стационарна состојба.



Слика 34. Нелинеарен модел на хидроенергетски објект со управување засновано на NN, NARMA во комбинација со PID управување

На Слика 35 е претставена споредба на одзивите за механичката моќност кога како управувачка техника се користи комбинирано управување, NARMA и PID управување и само PID управување. Одзивот со сина линија ја означува механичката моќност доколку се вметне комбинирано управување, NARMA и PID, додека одзивот со портокалова боја го означува управувањето само со PID управување.



Слика 35. Споредба на одзивот за механичката моќност при користење на комбинирано управување - NARMA и PID и управување само со PID [108]

Од одзивот може да се види дека кога се применува техника на комбинирано управување, NARMA и PID, одзивот на механичката моќност – сина боја е побрз и има побрзо време на стабилизирање, но се појавуваат одредени осцилации/прескокнувања при постигнување на стационарната состојба, додека пак управувањето само со примена на PID, одзивот со портокалова боја прикажува одзив со бавно постигнување на стационарната состојба и бавно стабилизирање во истата.

Параметрите користени за подесување на невронската мрежа се прикажани во Табела 6.

Табела 6. Параметри за мрежата од управување засновано на NN кај нелинеарен систем

Структура на мрежата	
Број на скриени слоеви	10
Период на семплирање	0.01 [s]
Тип на АФ	Tanh и Relu
Алгоритам за оптимизација	LMA
Податоци за тренирање на мрежата	
Број на податоци за тренирање	3000
Број на влезови во мрежата	1
Број на излези од мрежата	1
Број на епохи	2500

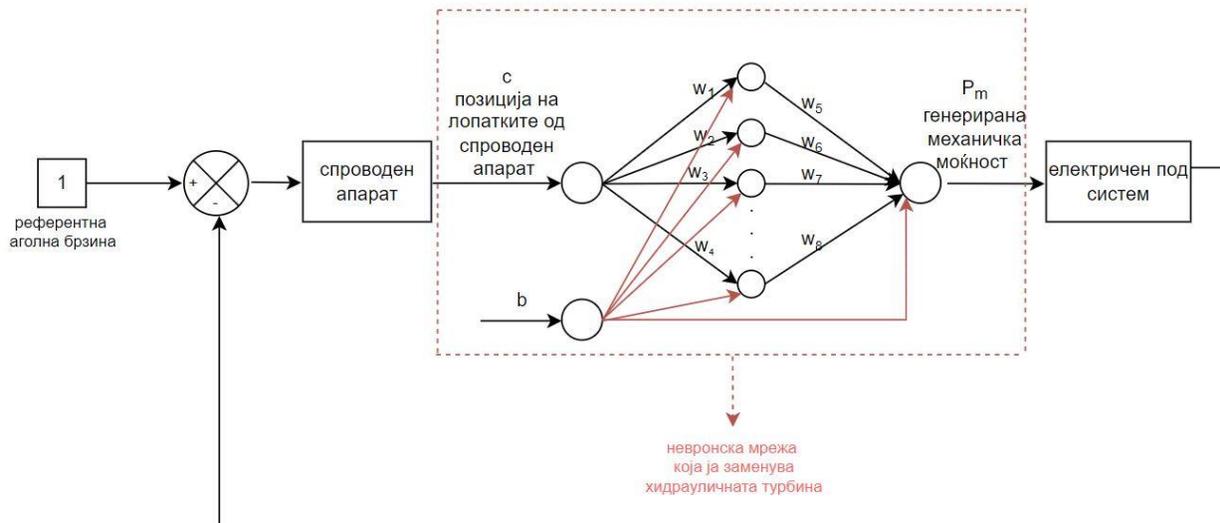
Доколку се споредат Табела 4, Табела 5 и Табела 6, а согласно одзивите добиени од линеарните и нелинеарните модели може да се забележи дека алгоритмот за оптимизација е непроменет, АФ се непроменети, единствени хиперпараметри што се менуваат се бројот на епохи, број на скриени слоеви и брзината на учење на самото управување засновано на NN. Овие се параметри кои не се пресметуваат туку едноставно се дефинираат во зависност од динамиката на моделот којшто се анализира.

4.5 Директна примена на невронска мрежа кај изолирана работа на хидроенергетски објект

Во оваа поглавје се анализирани повеќе пристапи за примена на NN со цел да се види нивното влијание на динамиката на хидроенергетскиот објект. Анализите се направени независно на линеарните, но и на нелинеарните модели.

Првиот пристап за примена на NN во моделот е целосна замена на математичкиот модел на турбината директно со NN. Во овој случај влезот во NN е отвореноста на спроводниот апарат, додека излезот од мрежата е генерираната механичка моќност. Податоците што се потребни за да се направи целосна замена на математичкиот модел со NN се измерени вредност за отвореноста на спроводниот апарат и од генерираната механичка моќност. Со директно внесување на NN во моделот, согласно достапното податочно множество, се прави DT на хидрауличната турбина со помош на науката за обработка на податоци и ANN. Примената на DT има предност во тоа што за симулација на еден објект на управување не е потребно да се внесуваат математички модели, во овој случај математичкиот модел на хидрауличната турбина, доволно е квалитетно податочно множество.

На Слика 36 е претставено директно внесување на NN на местото на хидраулична турбина, а притоа може да се види дека влез во системот е отвореноста на лопатките од спроводниот апарат, додека излез е генерираната механичка моќност.

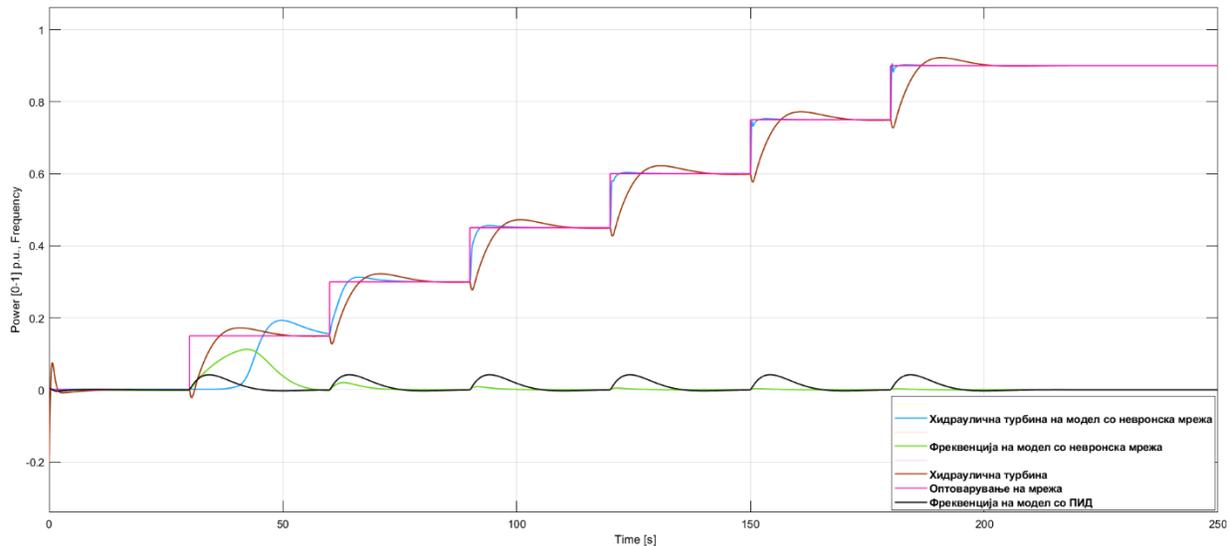


Слика 36. Директно внесување на невронска мрежа во моделот (целосна директна замена за хидраулична турбина)

Поради едноставноста на моделот, NN е составена од еден влез (отвореност на лопатките на спроводниот апарат), еден излез (генерирана механичка моќност), два неврони во скриениот слој, процентуалната распределбата на податоците за тестирање и тренирање е 20/80. Алгоритам за оптимизација на процесот е избран LMA.

На Слика 37 се прикажани одзивите од модел со и без вметната NN на местото на хидраулична турбина. Одзивот со кафеава боја (механичката моќност) доаѓа од моделот во којшто математички постои хидрауличната турбина, додека пак одзивот со сина боја (механичката моќност) доаѓа од моделот во којшто наместо моделот на хидраулична турбина постои NN. Доколку се споредат двата одзиви може слободно да се каже дека одзивот со сина боја на некој начин претставува идеален случај. Таквиот заклучок е поради тоа што самата NN секогаш се стреми да го пронајде најдоброто решение, а во овој случај таа го елиминира негативниот пад којшто се појавува поради влијанието на водата, цевководот, физичките карактеристики на хидроенергетскиот објект итн. Исто така може да се види дека станува збор за критично пригушен, стабилен и брз систем. Доколку пак се анализира фреквенцијата односно одзивот со зелена боја, може да се каже дека грешката помеѓу потребната фреквенција, 50 Hz односно 1 p.u. и постигнатата е речиси нула. Доколку пак се анализираат одзивот за механичката моќност означен со кафеава боја, односно кога математичкиот модел на хидрауличната турбина е внесен во самиот модел, се забележува присуството на негативниот пад кој го означува влијанието на цевководот, на водата и другите физички карактеристики кои влијаат на хидрауличната турбина. Тука станува збор за стабилен систем, но доколку се споредува со одзивот означен со сина боја, во тој случај е далеку побавен. Доколку исто така се анализира одзивот претставен со црна боја, а тоа е фреквенцијата кога во моделот е вметнат математичкиот модел на хидрауличната турбина и доколку се споредува со одзивот со зелена боја, тој со црна боја прави далеку поголема

грешка во однос на постигнатата и побаруваната фреквенција, но сепак да се напомене дека одзивот со зелена боја го претставува моделот идеално.



Слика 37. Споредба на одзиви од модели со и без замена на хидраулична турбина со невронска мрежа

4.6 Дефинирање на дигитален близнак и методологија за идентификација на систем со примена на машинско учење на прв хидроенергетски објект

4.6.1 Примена на метода на долга краткорочна меморија и повеќеслоен перцептрон за идентификација на управувачки систем

Бидејќи постојат повеќе методи за идентификација на систем [109], еден од пристапите кој што ретко се наоѓа во литературата како применуван, а посебно во областа на хидроенергетските објекти е идентификација на систем со примена на ML.

Целта за примена на методата за идентификација на систем е идентификација на динамиката на хидрауличната турбина преку одредување на преносна функција со примена на некои од методите на ANN и ML.

Со цел да се направи идентификација на преносна функција на хидраулична турбина во оваа истражување, а како што е теоретски и математички опишано во Глава 3 применети се две техники на ML и тоа LSTM и MLP.

За да се направи идентификација на систем, потребно е квалитетно исфилтрирано податочно множество преку кое ќе се генерира DT за објектот за којшто се прави идентификација со цел да може да се споредат карактеристиките на системот.

Со примена LSTM ќе биде прикажано влијанието на овој тип мрежи за идентификација на преносната функција на хидроенергетскиот објект.

Поради тоа што математички гледано, преносната функција на хидраулична турбина во линеарна форма е претставена во равенка 67,

$$\frac{\Delta P_m}{\Delta c} = \frac{1 - T_w s}{1 + \frac{T_w s}{2}} \quad (67)$$

може да се каже дека станува збор за систем со еден пол и една нула, односно станува збор за систем од прв ред. За да се направи идентификација на систем односно одредување на преносна функција на хидраулична турбина во предвид се земени податочни множества каде што влез во системот е отвореноста на лопатките на спроводен апарат, додека излез од системот е генерираната механичка моќност. Податочните множества искористени за идентификација на хидраулична турбина која што се користи во првиот хидроенергетски објект, го сочинуваат измерени вредности кои ги опишуваат динамичките карактеристики на самиот објект на управување. Ако истото се претстави на блок дијаграм за поедноставен приказ, би изгледало како на Слика 38.



Слика 38. Блок дијаграм за идентификација на систем

За да се направи идентификација на систем со помош на NN, потребно е измерените вредности од податочното множество да се распределат како влез и излез од системот. Правилната распределба на податочното множество овозможува правилно и точно одредување на преносната функција.

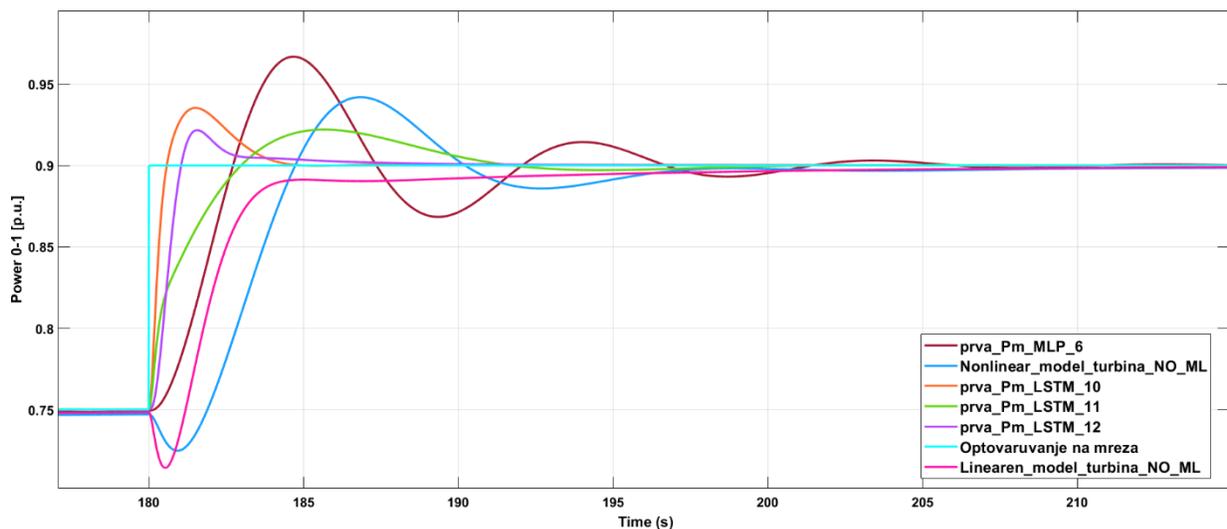
Во Табела 7 се прикажани различни преносни функции за хидрулична турбина добиени со примена на различни алгоритми на ML и различни конфигурации на NN. Иако за математичка репрезентација на хидраулична турбина (линеарна и нелинеарна) се користат равенките од 3 до 11 и 67, кога се прави идентификација на систем со примена на методите на ML, потребно е квалитетно податочно множество и влезна информација за бројот на полови и нули од кои би требало да се состои функцијата. Добиените преносни функции се за прв и втор реален хидроенергетски објект каде што со примена на LSTM и MLP методата се добиени различни преносни функции за хидраулична турбина. Резултатите од симулациите за добиените преносни функции како што е прикажано на Слика 39 и Слика 40 се споредени со одзивот добиен од експериментално измерени вредности за вистинска турбина од **првиот** хидроенергетски објект. Од одзивите може да се види и заклучи дека примената на MLP или LSTM методата за идентификација на систем со користење на квалитетно податочно множество е можно и дека добиените резултати се споредливи со одзивот од реалната постројка. Но доколку се направи подетална анализа на одзивите, може да се види дека негативниот пад којшто се појавува кај одзивот за реалната механичка моќност, е изоставен односно при дефинирање на преносната функција, алгоритмите на ML, ги сметаат тие вредности како непотрбни, па при процесот на тренирање и тестирање, дел од податоците ги отфрлаат како неважни пред истите да одат на валидирање и дефинирање на вредностите во половите и нулите за генерирање на преносната функција. Во Табела 7

првите 4 (четири) редици се однесуваат на преносни функции за прв реален хидроенергетски објект, додека редица 5, 6 и 7 се однесуваат на втор реален хидроенергетски објект. Исто така, бидејќи се менува оригиналната преносна функција, кај дел од разгледуваните одзиви од симулациите, потребно е да се заменат и вредностите на константите на PID управувањето. Изборот на константи на PID е направено на тој начин што преку Ziegler-Nichols методата се дефинираат гранични вредности за секоја константа посебно, а потоа со примена на алгоритмите на ML фина се подесуваат нови вредности за константите на PID. Генерално кај моделот од втор реален хидроенергетски објект кај сите модели се задржани истите вредности за константите на PID, додека кај првата реална хидропостројка, вредностите се заменети. При тоа, оригиналните вредности на константите се $K_p=2$, $K_i=0.465$ и $K_d=1.04$.

Табела 7. Приказ на сите преносни функции за хидрулична турбина добиени со примена на ML

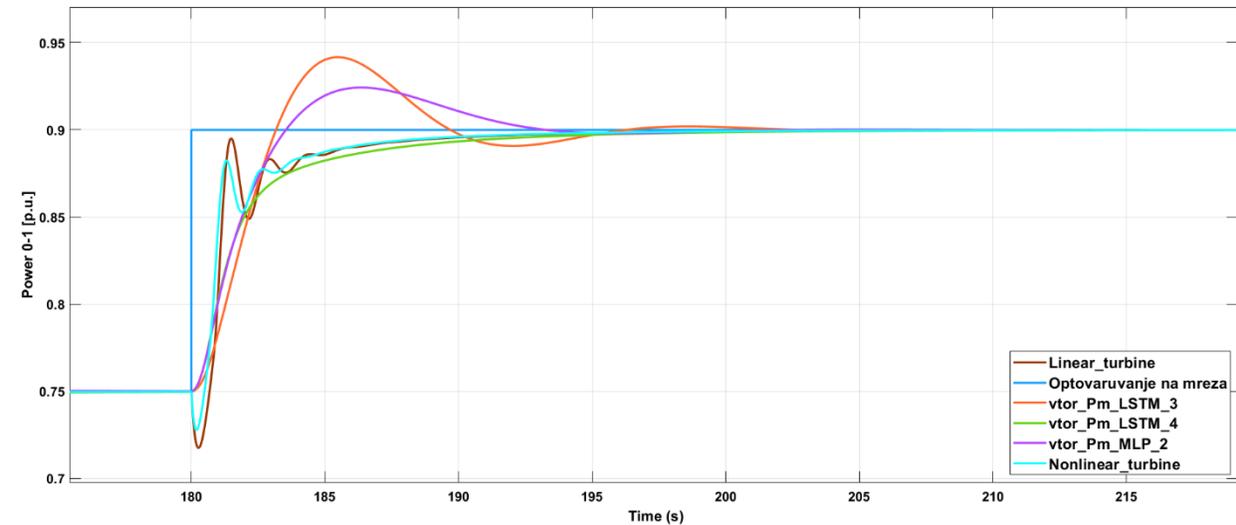
Ред . Бр	Име на модел	Метода	Преносна функција	Вредности за ПИД	Тип на невронска мрежа	Постројка
1	prva_Pm_LS TM_12	LSTM	$\frac{-0.73538}{-0.15792 \cdot s - 0,0957}$	$K_p=2.8455$ $K_i=0.49504$ $K_d=3.235725$	3 слоја - 256/128/64 tanh/tanh/softmax ADAM, LR=0,01, број на епохи=100	прва
2	prva_Pm_LS TM_11	LSTM	$\frac{s + 0.680685}{0.75274 \cdot s + 0.1024}$	$K_p=2.8455$ $K_i=0.49504$ $K_d=3.235726$	3 слоја - 156/58/24 tanh/tanh/tanh ADAM, LR=0,01, број на епохи=100	прва
3	prva_Pm_LS TM_10	LSTM	$\frac{s + 0.8201}{0.1874 \cdot s - 0.06426}$	$K_p=3.6$ $K_i=0.3$ $K_d=1,285$	2 слоја - 56/28 tanh/tanh ADAM, LR=0,001, број на епохи=100	прва
4	prva_Pm_ML P_6	MLP	$\frac{s+0.834}{s^2 + 1.046 \cdot s + 0.261}$	$K_p=3.6$ $K_i=0.3$ $K_d=1.285$	2 слоја - 20/8 tanh/tanh ADAM, LR=0,001, број на епохи=50	прва
5	vtora_Pm_LS TM_3	LSTM	$\frac{0.4752}{1.024 \cdot s + 0.1829}$	$K_p=3.6$ $K_i=0.46$ $K_d=3.4$	3 слоја - 256/128/64 tanh/tanh/tanh ADAM, LR=0,01, број на епохи=100	втора
6	vtora_Pm_LS TM_4	LSTM	$\frac{s+0.4537}{s^2 + 1.496 \cdot s + 0.5596}$	$K_p=3.6$ $K_i=0.46$ $K_d=3.4$	2 слоја - 156/88/24 tanh/tanh/tanh ADAM, LR=0,001, број на епохи=100	втора
7	vtora_Pm_M LP_2	MLP	$\frac{s+0.5768}{s^2 + 0.8896 \cdot s + 0.1968}$	$K_p=3.6$ $K_i=0.46$ $K_d=3.4$	3 слоја - 40/10/4 relu/relu/relu ADAM, LR=0,01, број на епохи=1000	втора

Од Слика 39 може да се види дека одзивите со новите преносни функции (Prva PM LSTM 10 – портокалова боја, Prva PM LSTM 11 – зелена боја, Prva PM LSTM 12 – виолетова боја, Prva PM MLP 6 – кафеава боја) особено добиените со примена на LSTM методата, покажуваат добри динамички карактеристики за механичката моќност на хидрауличната турбина. Додека преносната функција добиена со примена на MLP методата се карактеризира со големи прескоци и осцилации чии што динамички карактеристики се послаби за разлика од одзивите добиени со примена на LSTM методата. Сепак сите одзиви добиени со примена на ML, новите преносни функции како што веќе беше погоре напоменато, губат важна карактеристика, а тоа е негативниот пад којшто се појавува како резултат на физичките карактеристики на хидроенергетски објект (особено цевководот и др.). За таа цел примената на LSTM и MLP во задачата за идентификација на систем се посочуваат како несоодветни методи иако податочното множество достапно за обработка броеше повеќе од 190.000,00 податоци. Потребно е да се направи анализа и проба со други техники на ML со цел да се провери типот на преносна функција која што ќе се генерира како решени, но да се провери точноста и реалноста на добиените одзиви.



Слика 39. Идентификација на систем со примена на LSTM и MLP метода на ML за прв реален хидроенергетски објект

Истото важи и за одзивите добиени со примена на LSTM и MLP методата за втор реален хидроенергетски објект прикажани на Слика 40. Одзивите покажуваат добри динамички карактеристики, но при анализа на реалната интерпретација на одзивот, повторно исто како и на Слика 39 недостасува негативниот пад којшто се појавува како резултат на физичките карактеристики на хидроенергетски објект (особено цевководот). Поради тоа што користените методи на ML кај втор реален хидроенергетски објект се соочуваат со истите проблеми како и кај првата, заклучокот останува ист, а тоа е да се направи анализа и проба со други техники на ML со цел да се провери типот на преносна функција која што ќе се генерира како решени, но да се провери точноста и реалноста на добиените одзиви.



Слика 40. Идентификација на систем со примена на LSTM и MLP метода на ML за втор реален хидроенергетски објект

4.7 Предвидување на константите на пропорционално, интегрално и диференцијално управување со помош на машинско учење

Како што беше објаснето во Глава 3, примената на ML во овој докторски труд е искористено за предвидување на константите на PID управувањето.

Во претходното поглавје беше презентираан методот на Ziegler-Nichols со цел скратување на работното подрачје и можноста за грешка на ML. Но во ова поглавје, нема да се примени методата Ziegler-Nichols со цел одредување на подрачјето во кое треба да се движат пропорционалната, интегралната и диференцијалната константа. Тоа е направено за да на употребената метода од ML се даде поголем простор за предвидување поголем број комбинации за секоја од константите на PID управувањето.

Најпрво се формира податочно множество со околу 2500 податоци за параметрите посебно за пропорционалната, интегралната и диференцијалната константа кои во NN се дефинирани како излезни вредности. Како влезни параметри во NN се зададени измерени вредности за генерираната механичка моќност од две различни мерења. Генерираната механичка моќност се задава како влезен параметар за при процесот на ML односно избраните вредности за пропорционалната, интегралната и диференцијалната константа да се прилагоди спрема таа механичка моќност која се смета дека дава добра динамика на системот.

Зададените гранични вредности за константите се следни, за пропорционалната константа: од 1 до 5 генерирани се 2500 децимални вредности. За интегралната константа: од 0 до 3 генерирани се 2500 децимални вредности и за диференцијалната константа: од 0 до 2 генерирани се 2500 децимални вредности. Така генерираните вредности се дефинирани како излез од системот кој што треба да направи предвидување која комбинација од податочното множество се соодветна комбинација за дефинираните влезни вредности, односно за соодветната генерирана механичка моќност. Во Табела 8 се претставени

реалните вредности, додека во втората колона се запишани предвидените вредности за константите на PID управувањето добиено со примена на ML. Во третата колона е дефиниран типот на невронска мрежа искористена за предвидување на константите на PID. Може да се заклучи дека и покрај спојот на различни вредности за хиперпараметрите, кадешто секој параметар си има посебно влијание и значење во добивањето на излезни вредности, најголемо влијание врз предвидувањето на вредностите конкретно на константите на PID управувањето има AF бидејќи таа и дава динамика на невронската мрежа како истата би можела да работи со податочни множества за нелинеарни модели.

Во однос на структурата на NN, секој хиперпараметар има соодветно значење и влијание при добивањето на излезниот резултат. Па така, за поголеми вредности на брзината на учење доведува до побрзо конвергирање, но доколку вредноста се прилагоди да биде преголема, ќе му направи *overfitting* на моделот. Во однос на бројот на слоеви и неврони, се одредува капацитетот на моделот да учи покомлексни состојби и патерни. Користењето на поголема мрежа во одредени ситуации значи моделирање на покомлексни соодноси помеѓу параметрите во податочното множество, но преголема мрежа за помалку комплексни податочни множества значи доведување до *overfitting* или *underfitting*. Значењето на AF е важно пред се кај нелинеарни модели бидејќи преку тоа се чита и учи динамиката на моделот. Бројот на епохи се важни бидејќи со нив се одредува колку пати алгоритмот за учење прави пресметка низ целото податочно множество. Повеќе епохи може да го подобрат учењето, но може да доведат до *overfitting*. Покрај изборот на најсоодветен оптимизатор, типот на алгоритам, соодветното прилагодување на вредностите на хиперпараметрите е еден исто така најважен дел при конфигурацијата на NN. Согласно структурата на мрежата прикажани во Табела 8 и одзивите прикажани на Слика 41, Слика 42 и Слика 43, ќе се направи анализа на начинот на влијание на NN при предвидување на константите на PID и нивно влијание на динамичките карактеристики на системот.

Табела 8. Примена на ML за предвидување на вредностите на PID управување

Ред. Бр	Реални ПИД	Вредности за ПИД - ML	Тип на невронска мрежа	Постројка
1	Kp=2 Ki=0,456 Kd=1,04	Kp=3.0456 Ki=1.5047 Kd=1.0376	два слоја 134/55/3 АФ - tanh/tanh/linear АДАМ оптимизатор број на епохи - 150 брзина на учење - LR=0,01	прва линеарен и нелинеарен модел
2	Kp=2 Ki=0,456 Kd=1,04	Kp=4 Ki=0.9 Kd=1	два слоја 134/55/3 АФ - tanh/linear/linear АДАМ оптимизатор број на епохи - 150 брзина на учење - LR=0,01	прва нелинеарен модел
3	Kp=2 Ki=0,456 Kd=1,04	Kp=2.513216 Ki=0.539 Kd=0.4857	два слоја 134/55 АФ - tanh/linear АДАМ оптимизатор број на епохи - 150 брзина на учење - LR=0,01	прва нелинеарен модел
4	Kp=2 Ki=0,456 Kd=1,04	Kp=2.522996 Ki=0.456009 Kd=0.48257	два слоја 20/8 АФ - tanh/tanh АДАМ оптимизатор број на епохи - 50 брзина на учење - LR=0,001	прва нелинеарен модел
5	Kp=3,4 Ki=0,456 Kd=3,6	Kp=2.957487 Ki=1.4251481 Kd=1.0417138	два слоја 132/82 АФ - tanh/tanh АДАМ оптимизатор број на епохи - 100 брзина на учење - LR=0,001	втора нелинеарен модел

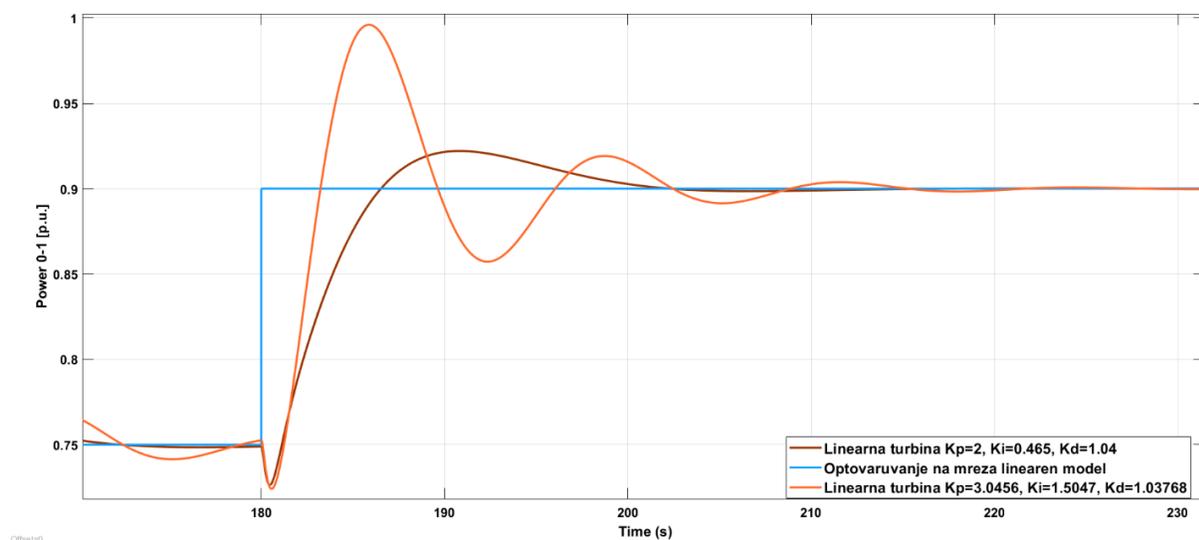
На Слика 41 е прикажана разликата помеѓу одзивот со кафеава боја за вредности $K_p=2$, $K_i=0.465$ и $K_d=1,04$ (реални вредности) и одзивот со портокалова боја за $K_p=3,0456$, $K_i=1,5047$ и $K_d=1,0376$ (предвидени вредности со примена на ML). Овие одзиви ја прикажуваат генерираната механичка моќност за линеарна репрезентација на хидраулична турбина. После анализа на повеќе вредности за константите на PID добиени со помош на ML за примена кај линеарен модел на хидраулична турбина, најсоодветни резултати се добиени со вредностите како што е прикажано со портокаловата линија. Иако брзината на учење е подесена да биде ниска, бројот на епохи е голем и истиот обезбедува *overfitting*, од друга страна типот на АФ е соодветно избрана, но за линеарен модел, конфигурацијата на NN е доста сложена и таа дополнително допринесува за добивање на одзив кај којшто може да се забележи голем прескок и осцилации. Предвидените параметри, нема да ги задоволат потребите на системот со цел подобрување на неговите динамички карактеристики.

Како што е прикажано на Слика 42, одзивот со портокалова боја за $K_p=2$, $K_i=0,46$ и $K_d=1,04$ ги претставува вистинските вредности на константите за реален управувачки објект. Анализите на останатите одзиви ќе се одвиваат во споредба со одзивот со портокалова линија со цел добивање поефикасен, побрз и стабилен управувачки објект. Во однос на тоа, одзивот со светло плава боја за $K_p=3.456$, $K_i=1.5047$ и $K_d=1.0376$ додава најголеми прескокнувања и осцилации околу стабилна состојба што го прави системот агресивен при негово управување иако системот со овие вредности на PID е најбрз, но потребно му е многу долго време за да истиот се стабилизира. Таквиот одзив прави системот да биде непосакуван во оперативна средина. Одзивот со виолетова боја за $K_p=4$, $K_i=0,9$ и $K_d=1$ слично како и одзивот со светло сина боја, го прави системот да биде брз, но со големи прескокнувања и осцилации околу стабилна состојба. Доколку се анализира NN на двата одзиви т.е. редица 1 и 2 од Табела 8, може да се виде дека разлика се појавува кај AF која доведува до значително подобрување на одзивот и во однос на прескокнувањата и осцилациите. Одзивите со темно сина боја за $K_p=2,522$, $K_i=0,465$ и $K_d=0,4825$ и зелена боја за $K_p=2.513$, $K_i=0.53981$ и $K_d=0,48569$ се речиси идентични и имаат најдобри перформанси доколку се споредат со одзивот со портокалов боја. Одзивите со зелена и темно плава боја обезбедуваат брз и стабилен систем со минимални осцилации со мали пресоци. Согласно тоа, одзивот со темно сина боја за $K_p=2,522$, $K_i=0,465$ и $K_d=0,4825$ во оперативна средина може да даде систем со најдобри динамички карактеристики. Доколку се спореди NN за колона 3 и 4 т.е. за одзивот со темно сина и зелена боја, јасно е зошто одзивот со темно сина боја дава подобри карактеристики на управувачкиот систем. Тоа е така бидејќи ниски вредности на брзината на учење овозможува побрзо конвергирање кон глобалниот минимум, што значи предвидување на најоптимално решение за моделот којшто се разработува, но и доведува до генерирање или појава на најмалу пресоци и осцилации. Бројот на слоеви и неврони во секој од слоевите е оптимално избран со цел да се овозможи доволно капацитет колку е потребно за да моделот го научи податочното множество, но притоа да не се дојде до ситуација на *overfitting*. Во однос на бројот на епохи, значи колку пати алгоритмот за учење работи низ целосно достапното податочно множество. Поставување на поголем број на епохи, може да го подобри учењето, но исто така (доколку другите хиперпараметри не се добро прилагодени) да доведат до *overfitting*. Па во однос на тоа, помал број на епохи во комбинација со помала брзина на учење ќе дадат решение со подобри динамички карактеристики, како што е покажано преку одзивот со темно сина боја во споредба со сите останати. Во однос на изборот на AF, \tanh/\tanh обезбедува соодветно читање на нелинеарните својства на моделот од достапното податочно множество. Имајќи \tanh во последниот слој во одредени случаи доведува до помазно управување и минимизирање на пресоците и осцилациите за сметка на можност за појава на губење на дел од градиентите кои секако во овој случај не покажуваат некое значително влијание. Иако во однос на AF, најсоодветна комбинација би била \tanh/linear , како што е во одзивот со зелена линија, редица 3, но во таа ситуација голем дел од параметрите се променети, како на пример брзината на учење е поголема, бројот на неврони во слоевите е поголем, што дополнително внесува поголем прескок во одзивот на системот.

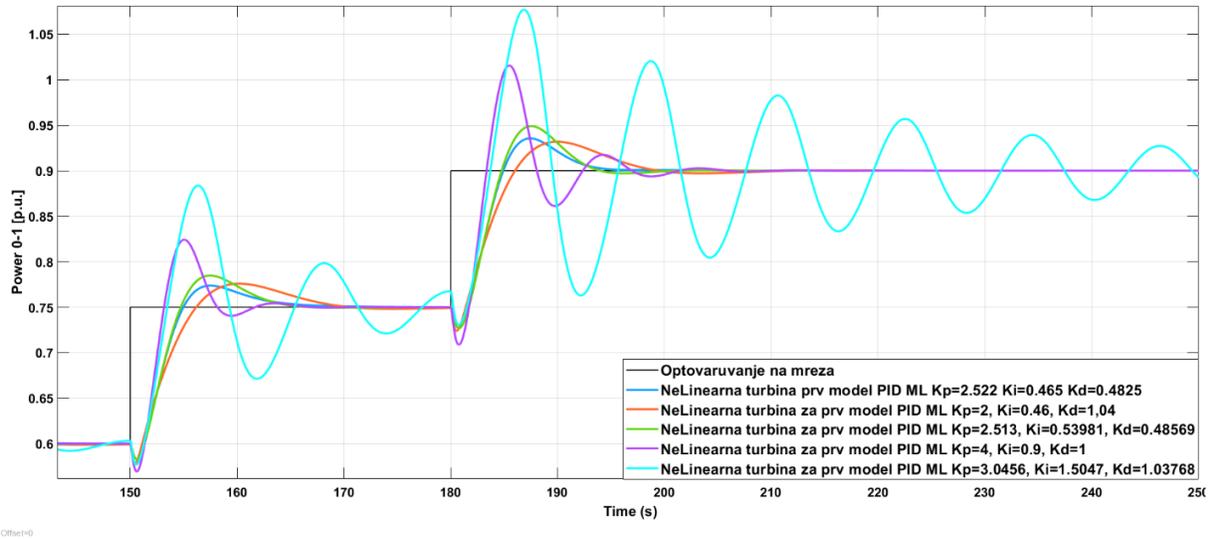
Најчесто кај NN, препорачливо е AF во крајниот слој да биде $\text{linear}/\text{relu}$ бидејќи таа често води кон побрзо учење и конвергирање кон глобален минимум поради нивната незаситена

природа (не задржуваат градиенти во вредносот 0 која не би можела да биде од помош при процесот на учење), што е најчесто корисно за примена при управување во реално време.

Кај NN, AF се нарекува заситена ако нејзините излезни вредности се приближуваат до асимптота како што се менуваат (зголемуваат) влезните вредности, предизвикувајќи го градиентот на функцијата да се приближи до нула. Ова однесување може да доведе до состојба да неврните стануваат помалку одговорни за влезните промени за време на тренирање на моделот/мрежата, успорувајќи го или дури и запирајќи го учењето. Спротивно на тоа, незаситена AF ги одржува градиентите различни од нула без оглед на влезната големина, обезбедувајќи ситуација да неврните останат одговорни и да обезбедат поефикасно учење. За таа цел, linear AF е најдобро да се користи кај излезните слоеви, а бидејќи е незаситена функција чиј градиент е константен за позитивни вредности, а со тоа го намалува ризикот од исчезнување на градиентите односно запирање на учењето.

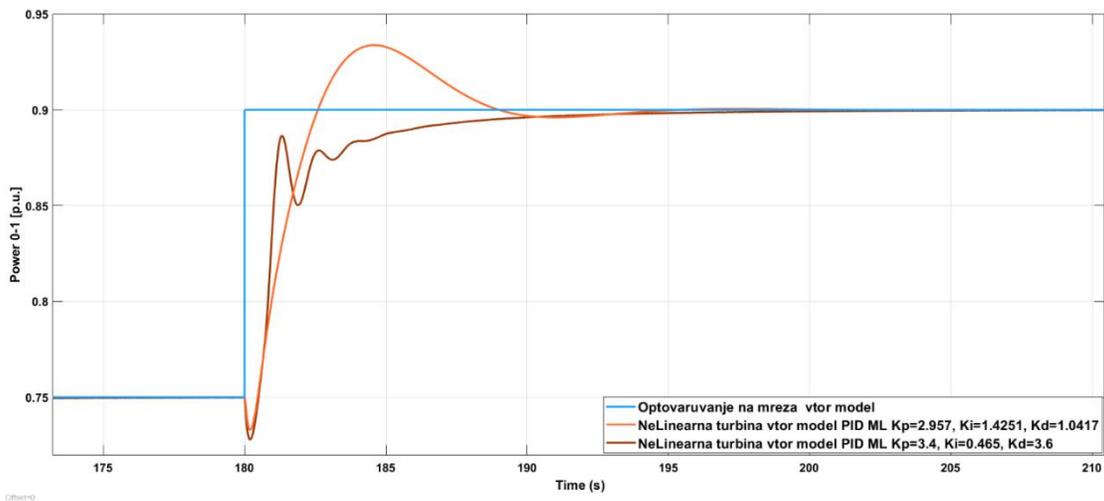


Слика 41. Споредба на одзивите кај линеарен модел на хидраулична турбина за константи на PID управувањето кај прв хидроенергетски објект



Слика 42. Споредба на одзивите кај нелинеарен модел на хидраулична турбина за константи на PID управувањето кај прв хидроенергетски објект

Кај втората хидроенергетска постројка исто така направено е предвидување на константите за PID. Доколку се направи споредба помеѓу одзивот со портокалова боја за $K_p=2.957$, $K_i=1.4251$ и $K_d=1.0417$ (предвидени вредности со ML) и одзивот со кафеава боја за $K_p=3.4$, $K_i=0.465$ и $K_d=3.6$ (за реалните вредности), одзивот со кафеава боја е поприфатлив бидејќи кај него не се појавуваат прескокнувања, а стабилизирањето во стационарна состојба е во исто време како и одзивот со портокалова боја. Доколку се анализира структурата на NN, може да се каже дека типот на AF е соодветно избран, брзината на учење е добро прилагодена, бројот на епохи можеби може да се намали под 100 согласно брзината на учење, бројот на слоеви исто така може да се намали под 50 во двата слоја соодветно. Сите овие препораки најверојатно ќе го намалат прескокот кај одзивот означен со портокалова боја чии параметри се добиени со предвидување на константите на PID со примена на ML.



Слика 43. Споредба на одзивите кај нелинеарен модел на хидраулична турбина за константи на PID управувањето кај втор хидроенергетски објект

Освен предвидување на константите на PID управувањето, направено е и предвидување на константите за PID при примена на техниката за управување со распоред на засилувања. За да се направи предвидување на PID константите за целото работно подрачје на хидрауличната турбина, искористена е секвенцијална NN која што за секој чекор посебно врши предвидување на пропорционалната, интегралната и диференцијалната константа.

Предвидувањето на константите во овој случај се прави со помош на Ziegler-Nichols метода за дефинирање на граничните вредности за константите на PID управувањето за секој чекор посебно. Подоцна тие гранични вредности се задаваат како целни излези за пропорционалната, интегралната и диференцијалната вредност. Во овој случај секој од чекорните влезови добива различни гранични вредности за константите на PID.

Податочното множество се состои од 939 параметри на влез и излез, додека моделот на мрежата е составен само од еден слој кој се состои од 156 неврони и излезен слој кој што се состои од 3 неврони. AF во скриениот слој е sigmoid, додека во последниот слој е linear. Бројот на епохи е 100, додека големината на факторот на учење е 0.03. Типот на оптимизаторот е ADAM.

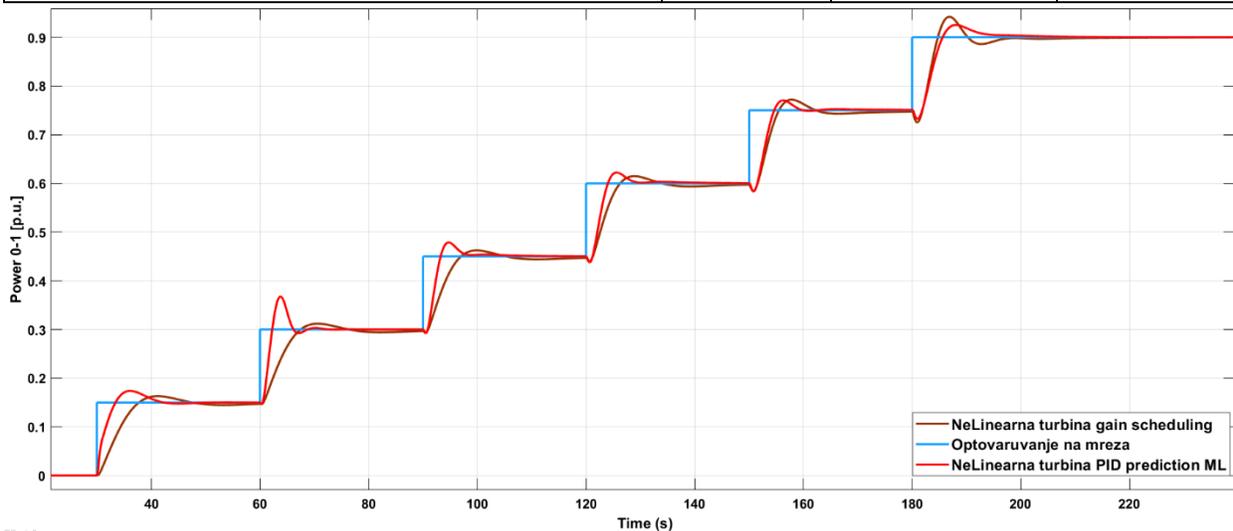
Доколку се споредат двете групи одзиви и тоа првата група е одзивот добиен со автоматско пресметување на константите за PID управувањето, а тие се означени со портокалова боја, додека втората група одзиви е означена со виолетова боја, а вредности за PID се предвидени со примена на ML. Притоа за првата група одзиви може да се каже дека станува збор за критично пригушен систем. Прилично брзо реагира на промена при премин од 0 па се до потребната механичка моќност. Во стационарна состојба системот е стабилен.

Доколку се анализираат вредностите од втората група одзиви каде што константите на PID управувањето се добиени со предвидување при примена на ML согласно Табела 9, од Слика 44 може да се каже дека со предвидените константи за PID системот добива одзив којшто има помал прескок и нема осцилации којшто е секако прифатлив за примена кај објекти на управување со голема инерција. Доколку се анализира механичката моќност може да се види дека негативниот пад кој е од голема важност поради тоа што преку тоа се покажува дека во симулираниот систем се земени во предвид влијанието на физичките карактеристики на водата и цевководот од хидроенергетскиот објект, е присутен во самиот модел.

Доколку се анализира мрежата којашто е користена при добивање на вредностите на константите, може да се каже дека се работи за мрежа која се состои од два слоја, изборот на AF е соодветен поради фактот дека во крајниот слој е сместена linear AF. Во однос на бројот на епохи и брзина на учење, еден со друг параметар се надополнуваат што значи дека за добивање на резултатите како што е прикажано на сликата, конвергирањето кон глобалниот минимум е прилично брзо.

Табела 9. Споредба на PID константи добиени со автоматско пресметување и со ML

Параметар	Kp	Ki	Kd
Вредности за PID од автоматско пресметување за чекор 1	2.991	0.24975	-14.9873
Вредности за PID од автоматско пресметување за чекор 2	3.1019	0.25205	-14.3325
Вредности за PID од автоматско пресметување за чекор 3	3.2402	0.25619	-13.7388
Вредности за PID од автоматско пресметување за чекор 4	3.4247	0.26341	-13.2217
Вредности за PID од автоматско пресметување за чекор 5	3.6659	0.27402	-12.7521
Вредности за PID од автоматско пресметување за чекор 6	3.68	0.3144	-7.2432
Вредности на PID за чекор 1 добиени со ML	4.2	1.592115239	2.7699
Вредности на PID за чекор 2 добиени со ML	5.1	1.942487145	3.3475125
Вредности на PID за чекор 3 добиени со ML	3.486	0.713905	4.255535
Вредности на PID за чекор 4 добиени со ML	2.7804	0.48994	3.94469
Вредности на PID за чекор 5 добиени со ML	2.4252	0.38249	3.84425
Вредности на PID за чекор 6 добиени со ML	1.926	0.372827	2.581256



Слика 44. Споредба на одзиви од нелинеарен модел на хидроенергетски објект со распоредување на засилувања за вредности добиени со ML и со метода на автоматско подесување на константи

4.8 Методологија за одредување временска константа на вода во цевководот (T_w) со примена на машинско учење

Временската константа на водата согласно равенка 14 зависи од повеќе параметри и тоа должината на доводниот цевковод, површината на напречниот пресек на доводниот цевковод, протокот низ турбината при максимална отвореност на лопатките од спроводниот апарат $s=1$ и притисокот на турбината. Тоа е коефициентот преку кој се дефинира преносната функција на турбината и во наједноставната, линеарна форма како што е прикажано со равенка 2, но и со нелинеарна математичка репрезентација. Поради тоа што е важен фактор при дефинирање на моделот, но и динамичките карактеристики на хидрауличната турбина, овој коефициент е искористен истиот да се генерира преку примената на ML односно преку методата на MLP и преку примена на LSTM.

Алгоритамот за дефинирање на T_w со примена на ML:

1. Се прават експериментални мерења со цел да се оформи податочно множество кое подоцна ќе се обработи со помош на ANN и ML (се дефинира кои големини/параметри е потребно да бидат анализирани).
2. Податочното множество се филтрира (доколку е потребно).
3. Се избира метода на ANN и ML со која ќе се обработуваат податочните множества.
4. Се дефинираат влезно и излезно податочно множество.
5. Се дефинираат хиперпараметри со кои ќе се моделира вештачката NN.
6. Се проектира мрежа која треба да ја предвиди временската константа на водата.
 - 6.1. Моделот се поставува како да е потребно да се одреди нула од преносната функција.
 - 6.2. Предвидената вредност се става во смулациски модел.
 - 6.3. Доколку има потреба, поради тоа што станува збор за нов модел на турбина, се избираат и нови константи за PID.
 - 6.4. Изборот на нови константи за PID управувањето се прави со рачно подесување, автоматско подесување или предвидување на вредностите со примена на некои од методите на ML.
 - 6.5. Да се пресмета Fort, оптималноста за моделите со нова преносна функција добиена со примена на ML и преносната функција добиена со пресметка за постоечката турбина.

Бидејќи во овој докторски труд се обработуваат две реални постројки од кои едната е таргет по чиј пример се води подобрувањето во динамичките карактеристики на втората, реална постројка, како целна или таргет излезна вредност се поставува механичка моќност според која ќе треба да се тренира и прилагодува NN. Целната вредност е основа со експериментално измерени податоци за активната механичка моќност од првата постројка според која е потребно да се добие T_w и да се добие слична или подобрена динамичка карактеристика. Како влезна вредност во мрежата е поставено податочно множество (составено од статички параметри) за активната механичка моќност превземени од системот за супервизорно управување и аквизиција на податоци.

Втората група резултати се кога на влез во NN ќе се постави податочно множество од отвореноста на лопатките од спроводниот апарат чии податоци се добиени со експериментално мерење направено на самиот хидроенергетски објект, додека на излез како целна вредност ќе се постави активната механичка моќност од првата хидропостројка според која е потребно да се прилагоди втората постројка согласно динамичките карактеристики.

Алгоритам за предвидување на временска константа на водата со примена на ML:

1. Дефинирање на потребни библиотеки за да може да се извршува пресметката.
2. Дефинирање на влезови (податочно множество за влезови).
3. Дефинирање на целни излези (податочно множество за целни излези).
4. Се дефинира типот на ANN со која што ќе се обработуваат податоците.
5. Се дефинира бројот на скриени слоеви и бројот на неврони во секој од слоевите.
6. Се дефинираат AF за секој од слоевите посебно.
7. Се дефинира тип на оптимизатор.
8. Се прави процентуална распределба на податоците за валидирање, тестирање и тренирање.
9. Се тренира моделот.
10. Се задава информација дека е потребно да се дефинираат нули со цел да се генерира вредност за временската константа на вода.
11. Се дефинира горната и долната граница на вредноста на T_w што е потребно да се добие.
12. Се вадат генерираните вредности за временската константа на водата.
13. Добиените вредности се поставуваат во симулациски модел во Simulink.
14. Се споредуваат добиените излези со излезите од моделот пред да се примени ML преку примена на MLP и LSTM.

Реалната, постоечка вредност на временската константа на водата за вториот хидроенергетски објект е $T_w=0.479$ (s), додека на првиот хидроенергетски објект $T_w=1.434$ (s).

Добиените вредности за временската константа на водата со примена на ML со користење на MLP и преку примена на LSTM се дефинирани во Табела 10 доколку како податочно множество на влезна страна се постави отвореноста на лопатките од спроводниот апарат, а на излез се дефинира активната механичка моќност. Како втора опција во однос на дефинирањето на влезните и излезните параметри, направена е комбинација на податочно множество на механичка моќност на влез чии што вредности (статички параметри) се превземени од SCADA системот на самата хидроенергетска постројка, додека податочното множество на излез се експериментални мерења направени од првата, референтна постројка (динамичките параметри).

Во Табела 10 и Табела 11 се означени некои од добиените вредности. Истите се презентирани со цел да се види дека примената на ML во некои делови од истражувањето,

може сериозно да направи грешка, а истата е потребно да се согледа преку анализа на претходно добиените резултати.

Доколку се анализираат вредностите добиени за RMSE и за функцијата на цел Fort за резултатите добиени за точка 1 до 4 од табела Табела 10, преку примена на методата на MLP доколку се комбинираат податочните множества за отвореност на спроводен апарат и активната механичка моќност, може да се каже дека колку е поблиску предвидената вредност на T_w до реалната, така RMSE е помала, како се зголемува вредноста на T_w , така RMSE расте, што е очекувано бидејќи се оддалечува од вредноста на веќе постоечката временска константа. Во исто време доколку се анализира и функцијата на цел може да се види дека разлика се појавува во четврта или петта децимала доколку се споредува вредноста на функција на цел за постоечката во споредба со вредноста добиена со предвидување преку ML.

Исто така доколку се анализираат и вредностите за T_w кои што се добиени со помош на ML од рен број 5 до 13, може да се види дека при примена на методата на MLP се добиваат резултати кои се поблиски и со помало RMSE, во споредба со резултатите кои се добиваат кога се применува методата на LSTM. MLP како метода е далеку поедноставна во зависност од LSTM методата, па затоа и од Табела 10 и Табела 11 може да се види дека вредноста на RMSE при примена на методата на MLP како поедноставна метода е помало, во споредба со методата на LSTM. Тоа е очекувано да биде така бидејќи се работи за обработка на податоци за кои не е потребна голема пресметковна моќ каде што информацијата се движи во еден правец без притоа да се земе во предвид влијанието на претходните информации. Тука се покажува дека не секогаш е неопходно да се искористи најјаката метода на ML или комплицирана NN составена од повеќе од еден скриен слој или огромен број неврони, пример повеќе од 100 при обработка и анализа на податоци за да се дојде до најсоодветен резултат бидејќи тоа секогаш не гарантира пресметка на најдобро решение на зададениот проблем. Тука може да се каже дека доколку ANN со цел или несвесно се искомплицира за да се добие најдобар резултат, тоа може да направи обратен ефект поради повеќе фактори од кои едниот од нив би можело да биде недоволен број податоци потребен на самата мрежа или преголема едноставност на влезните и целните вредности за обработка. Од тука произлегува дека не секогаш методите на ML се соодветни во сите сфери во анализа на податоците. Понекогаш е потребно поедноставен третман на податочните множества за да може да се извлечат најважните информации.

Табела 10. Споредба на RMSE и Fort при различни коефициенти за Tw при употреба на отвореност на спроводен апарат со активна механичка моќност за прв хидроенергетски објект

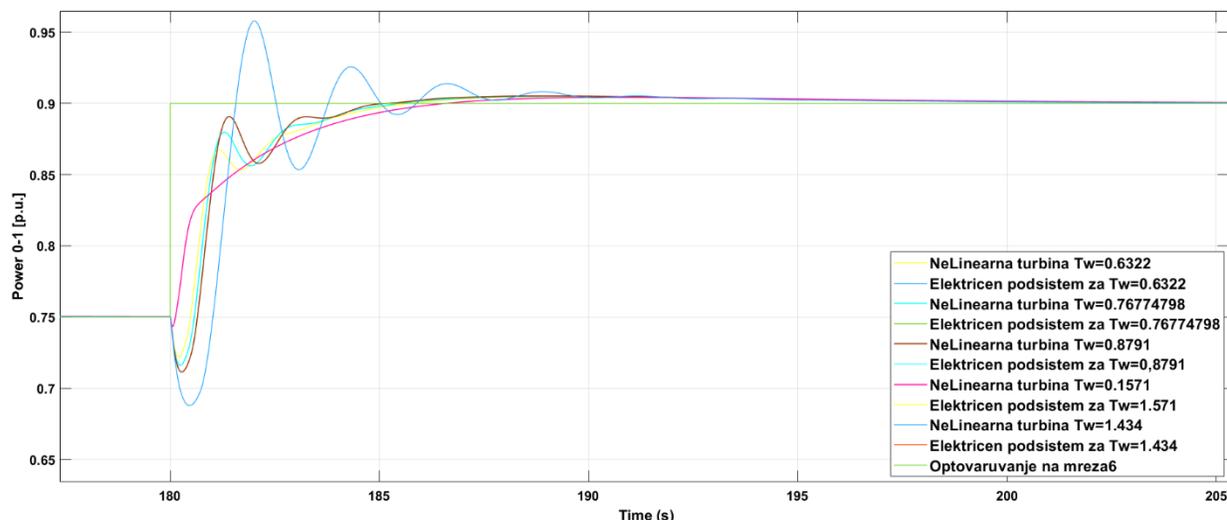
Ред. бр.	Повеќеслоен перцептрон Отвореност на спроводен апарат со активна механичка моќност	RMSE (%)	Fort
1	0,6322 (нелинеарен модел)	0,4 %	0,02858 0,02586
2	0,76774798 (нелинеарен модел)	0,4 %	0,02563 0,02564
3	0,8791 (нелинеарен модел)	0,4 %	0,02552 0,02553
4	0,1571 (нелинеарен модел)	0,3 %	0,02622 0,02626
	Мрежи со догла краткорочна меморија Отвореност на спроводен апарат со активна механичка моќност	RMSE (%)	Fort
5	0,5822 (нелинеарен модел)	0,7 %	0,02221 0,02443
6	0,93149 (нелинеарен модел)	0,9 %	0,02187 0,02409
7	0,2753 (линеарен модел)	0,07 %	0,00355 0,00357

Табела 11. Споредба на RMSE и Fort при различни коефициенти за Tw при употреба на активна механичка моќност од втора хидропостројка со активна механичка моќност од референтна хидропостројка

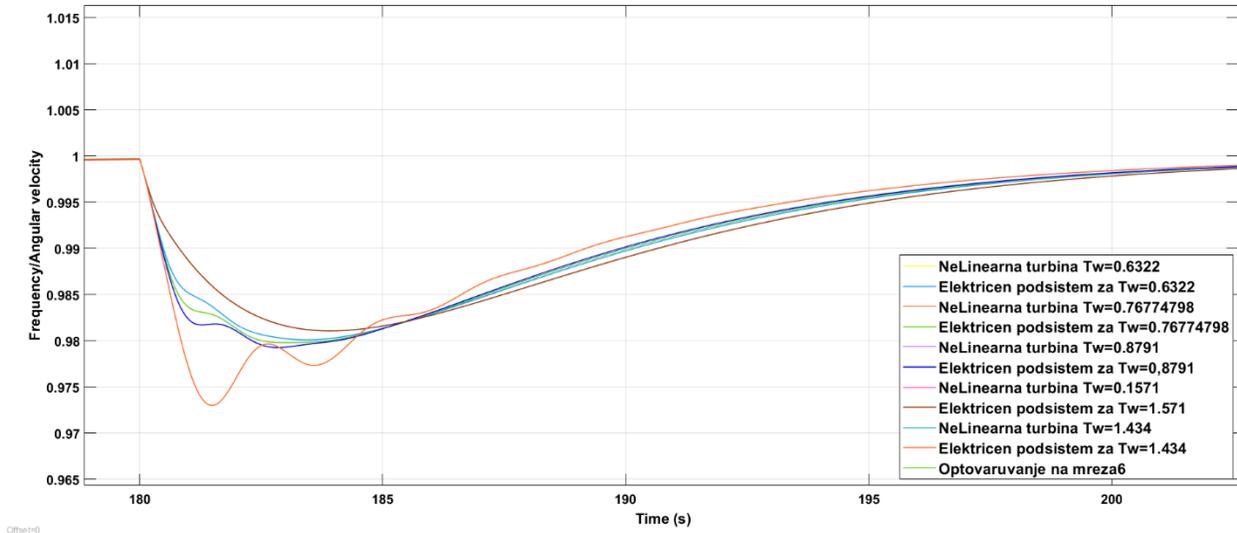
Ред. бр.	Повеќеслоен перцептрон Активна механичка моќност од втора хидропостројка со активна механичка моќност од референтна хидропостројка	RMSE (%)	Fort
8	0,195 (нелинерен модел)	0.3 %	0.02644 0.02649
9	0,52615 (нелинеарен модел)	0.3 %	0.026107 0.026123
10	0,60458 (нелинеарен модел)	8 %	0.49587 0.02617
	Мрежи со долга краткорочна меморија Активна механичка моќност од втора хидропостројка со активна механичка моќност од референтна хидропостројка	RMSE (%)	Fort
11	0,829 (нелинеарен модел)	76 %	0,00238 0,00457
12	0,8602 (нелинеарен модел)	0.9 %	0.02195 0.02417

13	0.87875963 (нелинеарен модел)	0,9 %	0,02193 0,024149
----	-------------------------------	-------	---------------------

На Слика 45 и Слика 46, претставен е збирен дијаграм за различни вредности на T_w добиени со примена MLP методата за прв реален хидроенергетски објект кадешто реалната вредност на $T_w=1.434$. Согласно резултатите од симулациите за генерираната механичка моќност, аголната брзина, RMSE и Fort, може да се каже дека доколку вредноста на T_w како дел од хидрауличниот подсистем е 0,175 се добива најмала вредност на $RMSE=0.3\%$, но и вредноста на Fort е во средина помеѓу највисоката и најниската. Доколку се анализираат одзивите за моќноста на турбината и фреквенцијата, може да се каже дека за $T_w=0.157$ се обезбедува одзив без осцилации, а брзината на постигнување на стационарна состојба е идентично и со остантите вредности на T_w . Одзивот на фреквенцијата за $T_w=0.157$ прави најмала грешка при обезбедување на стабилна работа на турбината во 50Hz.

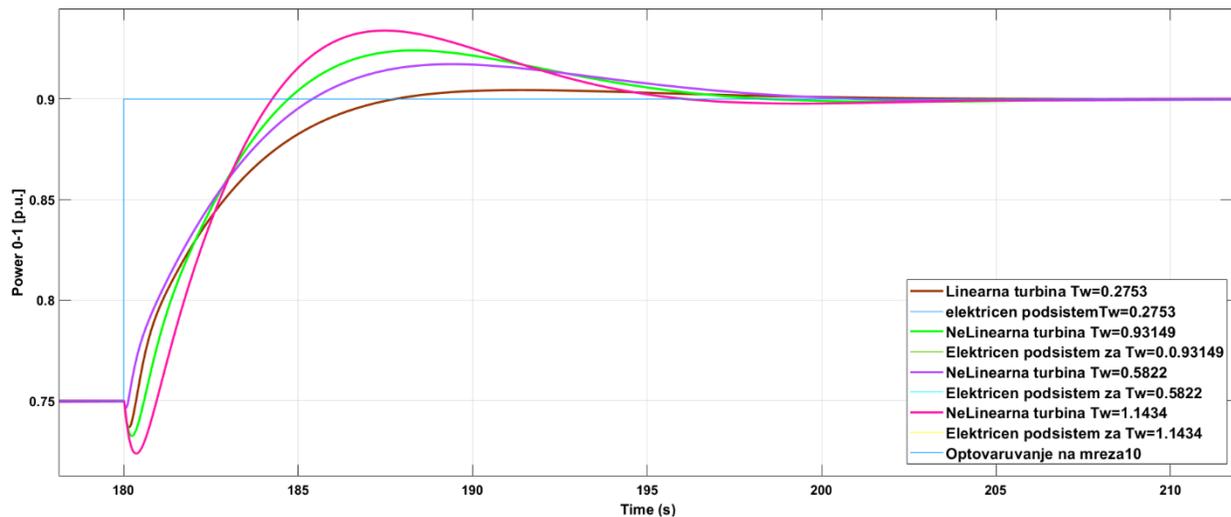


Слика 45. Примена на MLP за идентификација на временска константа на водата во цевководот $T_w= 0.6322$, $T_w=0.76774798$, $T_w=0.8791$, $T_w=0.1571$ добиена со ML за приказ на моќноста на турбината (прв реален објект на управување)

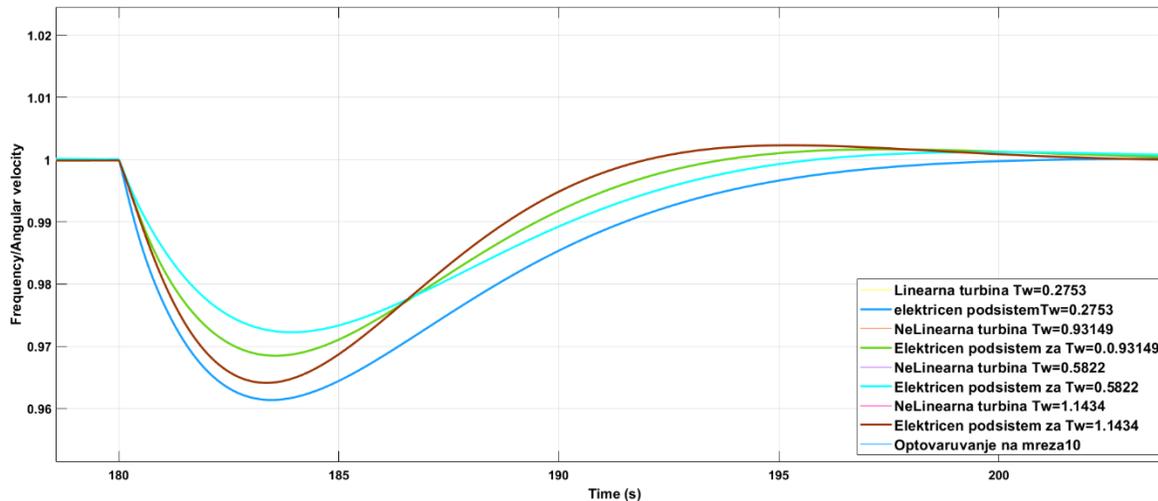


Слика 46. Примена на MLP за идентификација на временска константа на водата во цевководот $T_w = 0.6322$, $T_w = 0.76774798$, $T_w = 0.8791$, $T_w = 0.1571$ добиена со ML за детален приказ на фреквенција (прв реален објект на управување)

Доколку се анализираат одзивите од Слика 47 и Слика 48 може да се види дека доколку се земе во предвид хидрауличен подсистем со $T_w = 0.5822$, постигнувањето на стационарна состојба кај генерираната механичка моќност ќе биде побавно, но без прескок како што е со моменталната реална вредност, $T_w = 1.434$. Еквивалентно, доколку се разгледуваат одзивите на аголната брзина, односно за $T_w = 0.5822$, постигнувањето на 50 Hz ќе биде најефикасно односно со најмала грешка, како што е и прикажано во Табела 10.

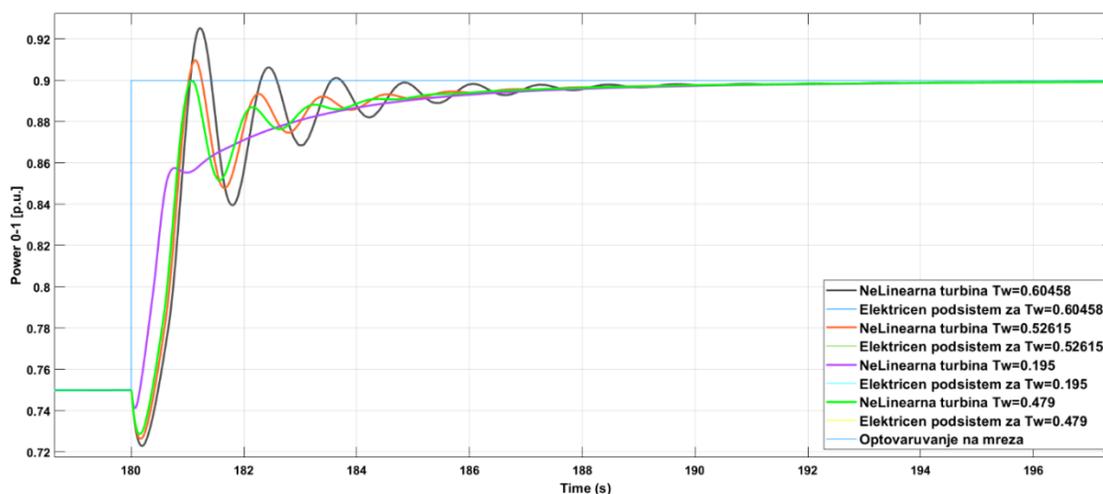


Слика 47. Примена на LSTM за идентификација на временска константа на водата во цевководот $T_w = 0.5822$, $T_w = 0.93149$, $T_w = 0.2753$ добиена со ML за приказ на моќноста на турбината (прв реален објект на управување)

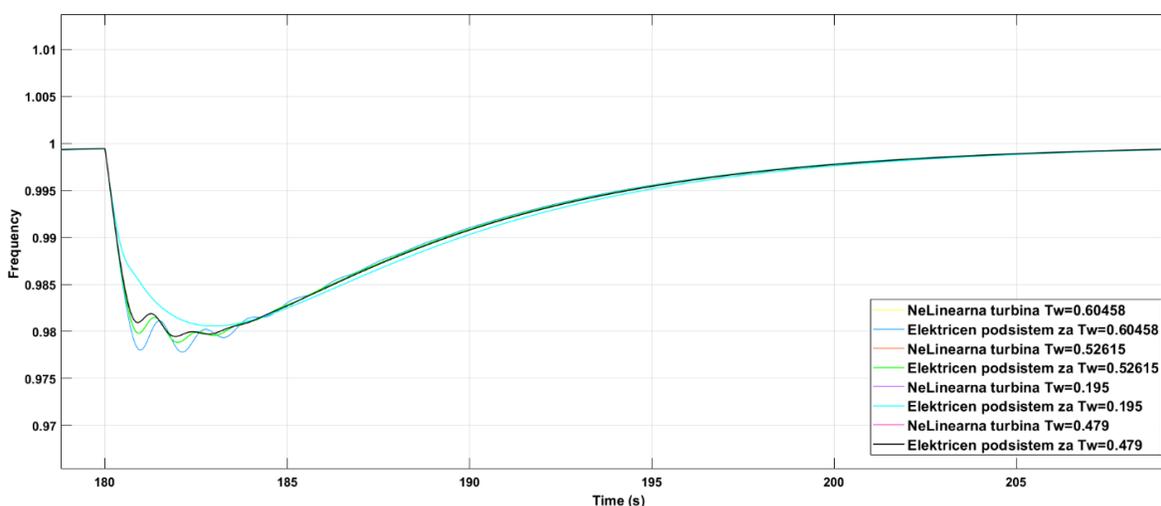


Слика 48. Примена на LSTM за идентификација на временска константа на водата во цевководот $T_w = 0.5822$, $T_w = 0.93149$, $T_w = 0.2753$ добиена со ML за приказ на фреквенција на турбината (прв реален објект на управување)

Одзивите прикажани на Слика 49 до Слика 52 се однесуваат на втор реален хидроенергетски објект врз кој се применети истите методи на ML и тоа MLP и LSTM. За втор реален хидроенергетски објект $T_w = 0.479$. На Слика 49 и Слика 50 се прикажани одзивите од примена на MLP методата. При анализа може да се каже дека за новодобиената константа $T_w = 0.195$ се добива одзив со најмала грешка, без осцилации при движење кон стационарна состојба и еднакво време на стабилизирање на системот во стационарна состојба како и одзивите со други вредности на T_w . При тоа може да се види дека за $T_w = 0.60458$, каде што RMSE е дури 8% и е најголема од зададените вредности, дава одзив со најголеми осцилации и исто време на постигнување на стационарна состојба како и за сите останати вредности на T_w . Истото се однесува и за анализата на одзивот на аголната брзина односно фреквенцијата од каде може да се види дека одзивот со светло плава боја ($T_w = 0.195$) со најмала грешка ја достигнува референтната вредност од 50 Hz.

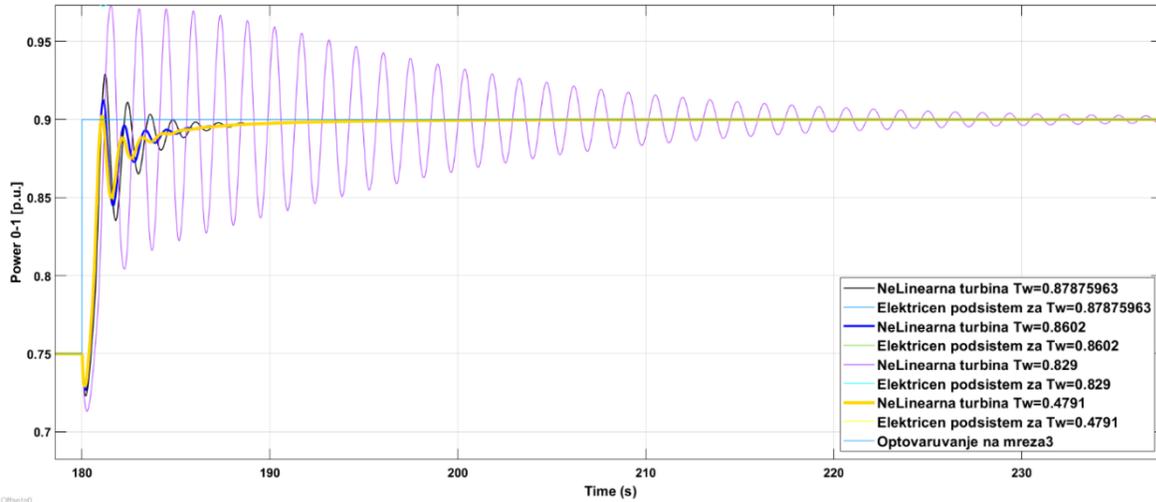


Слика 49. Примена на MLP за идентификација на временска константа на водата во цевководот $T_w = 0.195$, $T_w = 0.52615$, $T_w = 0.60458$ добиена со ML за приказ на моќноста на турбината (втор објект на управување)

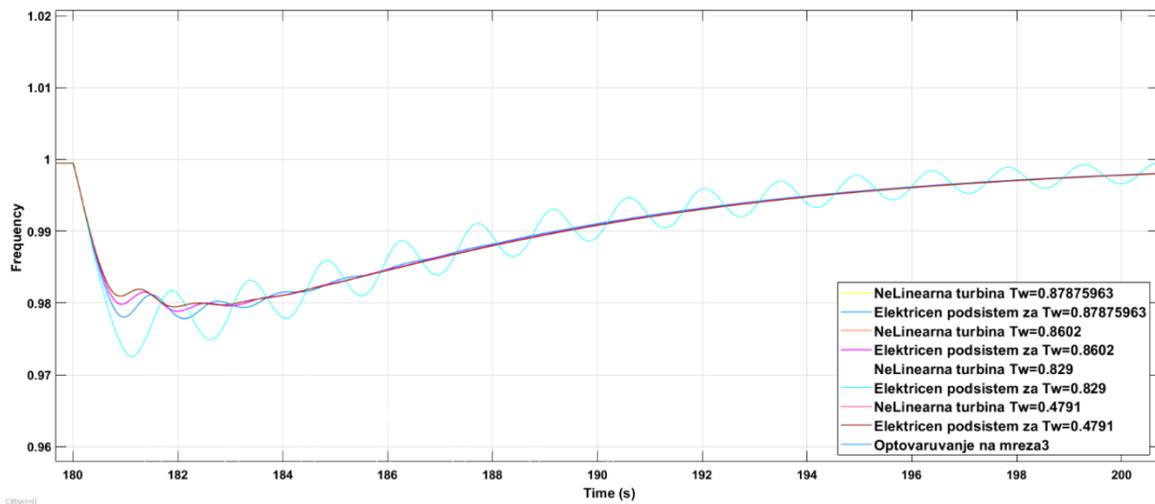


Слика 50. Примена на MLP за идентификација на временска константа на водата во цевководот $T_w = 0.195$, $T_w = 0.52615$, $T_w = 0.60458$ добиена со ML за детален приказ на фреквенцијата (втор објект на управување)

Доколку се анализираат резултатите прикажани на Слика 51 и Слика 52, за сите вредности на новодобиените T_w , се добиваат слични одзиви од каде како најсоодветен може да се избере $T_w = 0.8602$ или $T_w = 0.87875963$ бидејќи генерираат сличен одзив, но малку побрз во постигнувањето на стационарна состојба, а времето на смирување на осцилациите е слично како и кај постоечката вредност за T_w . Исто од Табела 11 може да се види дека за $T_w = 0.829$, $RMSE = 76\%$, а тоа може да се види и од одзивот кој постојано осцилира околу стационарна состојба со тенденција на намалување на осцилациите, но после многу долг временски период. Истото може да се забележи и кај одзивот за фреквенцијата односно аголната брзина, каде што вториот најдобар одзив се добива за $T_w = 0.806$.



Слика 51. Примена на LSTM за идентификација на временска константа на вода во цевководот $T_w = 0.829$, $T_w=8602$, $T_w=87875963$ добиено со примена на ML за детален приказ на механичката моќност (втор објект на управување)



Слика 52. Примена на LSTM за идентификација на временска константа на вода во цевководот $T_w = 0.829$, $T_w=8602$, $T_w=87875963$ добиено со примена на ML за детален приказ на фреквенцијата (втор објект на управување)

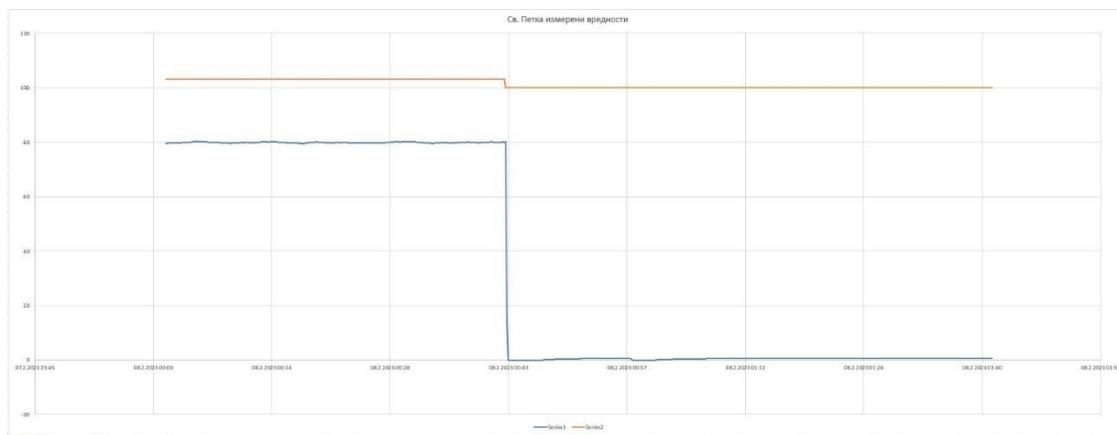
Доколку се направи анализа на сите временски константи на вода во цевководот – T_w , може да се види дека вредностите добиени со примена на MLP и LSTM се движат во рангот на реалната вредност што изнесува 0.479. Исто така ова е добар пример од каде што може да се каже дека не секогаш најмоќната метода и мрежа ќе даде најдобар резултат, понекогаш е доволно поедноставна метода како што е MLP за добивање задоволителни резултати кои ќе внесат подобрени динамички карактеристики на управувачкиот систем.

4.9 Достапни податочни множества за постоечки хидроенергетски објект за формирање дигитален близнак

Во ова поглавје ќе бидат прикажани дел од снимените податоци од хидроенергетските објекти (статички и динамички карактеристики) со кои се работеше во текот на ова истражување. Најпрво преку Слика 53 и Слика 54 се прикажани одзивите на механичката моќност (сина боја) и аголната брзина (портокалова боја). Овие податоци се статичките карактеристики на хидроенергетскиот објект превземени од SCADA системот за реалната хидропостројка каде што приклучувањето на мрежа се одвива во два чекори, со два чекорни влезови. Согласно снимените податоци, направени се и прилагодувања на симулациите како што е прикажано на Слика 55.



Слика 53. Измерени вредности од втор хидроенергетски објект (при вклучување на турбина) за отвореност на лопатки од спроведен апарат (сина боја) и фреквенција (портокалова боја) од 08.02.2023



Слика 54. Измерени вредности од втор хидроенергетски објект (при исклучување на турбина) за отвореност на лопатки од спроведен апарат (сина боја) и фреквенција (портокалова боја) од 08.02.2023

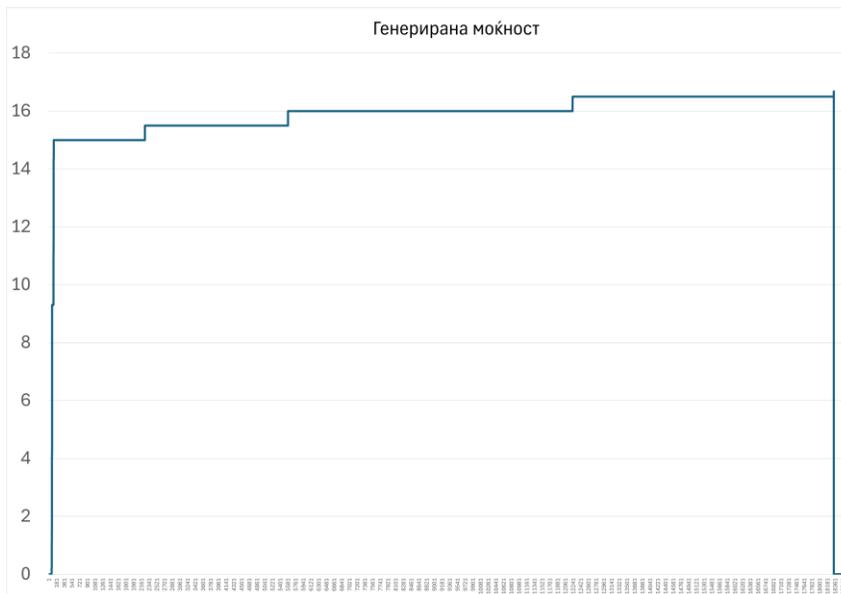
На Слика 55, претставено е податочното множество од втора, реална постројка за отвореноста на спроводниот апарат, искористено за дефинирање на методологија за

идентификација на систем, дефинирање методологија за проектирање на константите за PID управување, но и методологија за обработка на достапното податочно множество.



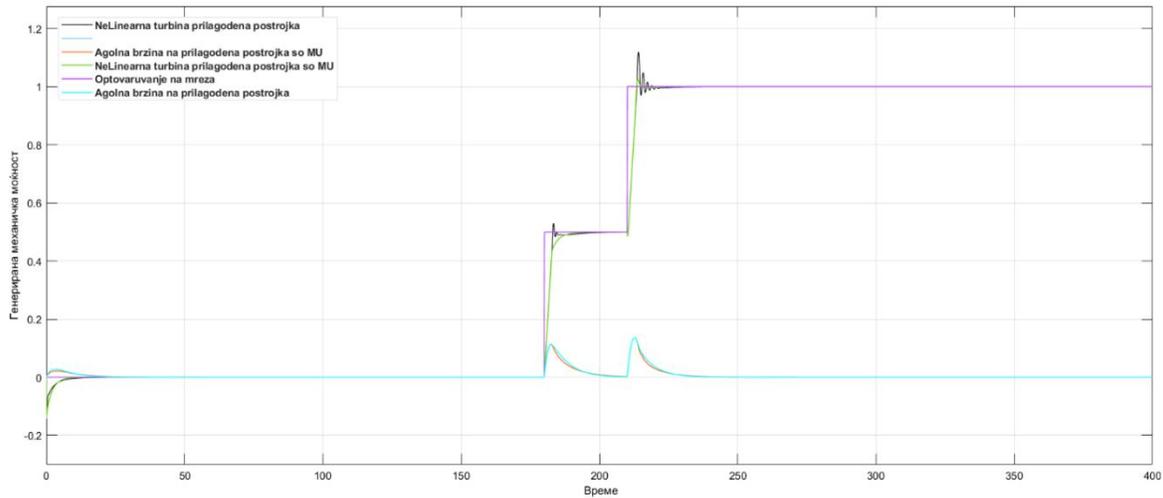
Слика 55. Податочно множество за превземено од SCADA на реалната постројка за отвореност на лопатки од спроводен апарат

На Слика 56 е прикажано податочното множество од втора, реална постројка за генерирана механичка моќност, искористено за дефинирање на методологија за идентификација на систем, дефинирање методологија за проектирање на константите за PID управување, но и методологија за обработка на достапното податочно множество.



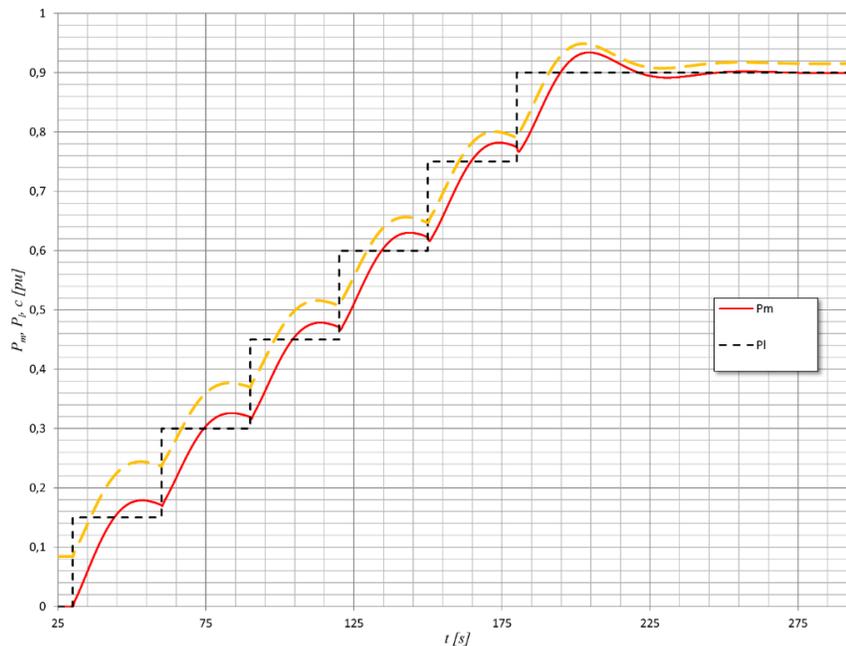
Слика 56. Податочно множество превземено од SCADA на реална постројка за генерирана механичка моќност

На Слика 57 е прикажано постигнувањето на потребната механичка моќност во два чекори кое се споредува согласно снимените/реалните податоци прикажани на Слика 53.

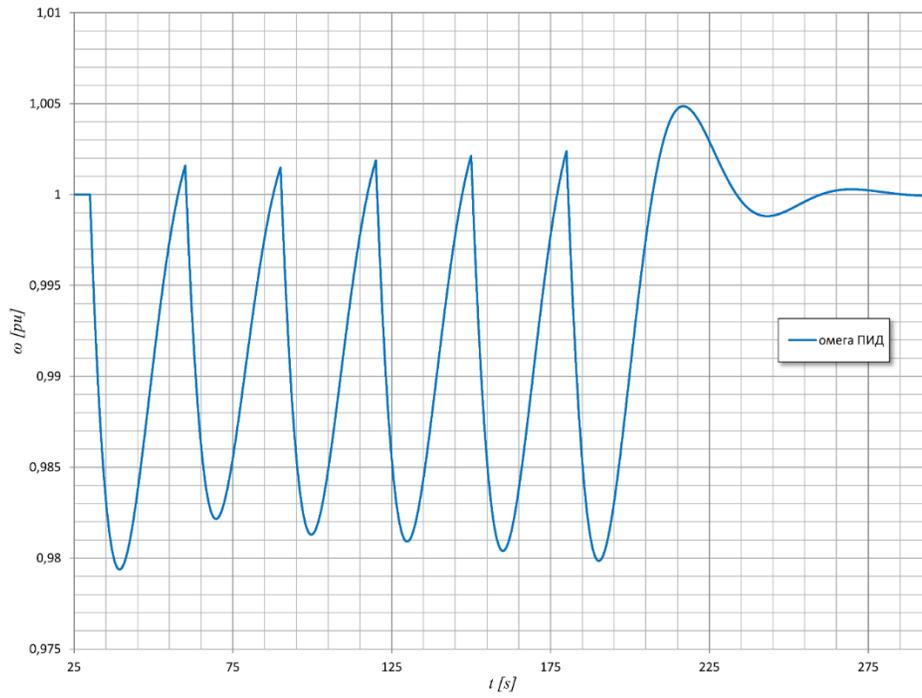


Слика 57. Смупациски модел од реалне хидроенергетски објект со два чекори за воспоставување на потребна механичка моќност при вклучување

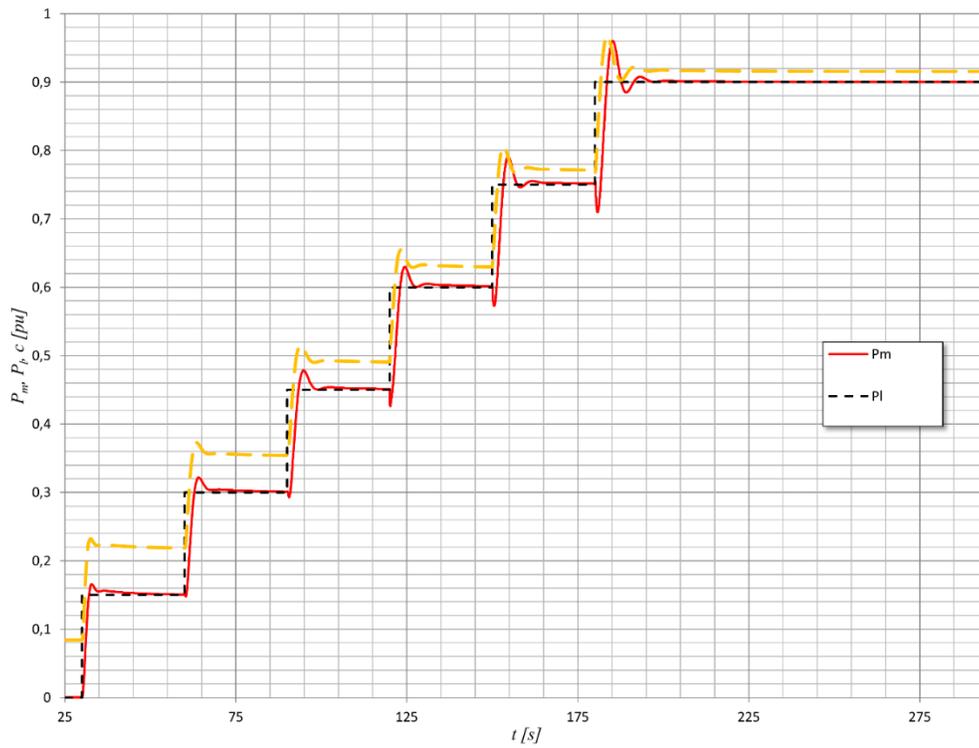
Споредбените карактеристики за генерираната механичка моќност и фреквенцијата преземени од направено мерење од првиот хидроенергетски објект при управување со распределување на засилувања за PID, со цел тренирање и валидирање на моделот од ML се претставени на Слика 58 и Слика 59. На Слика 60 и Слика 61 се претставени споредбените карактеристики за генерираната механичка моќност и фреквенцијата превземени од направено мерење (динамички карактеристики) од првиот хидроенергетски објект при управување со PID, со цел тренирање и валидирање на моделот од ML.



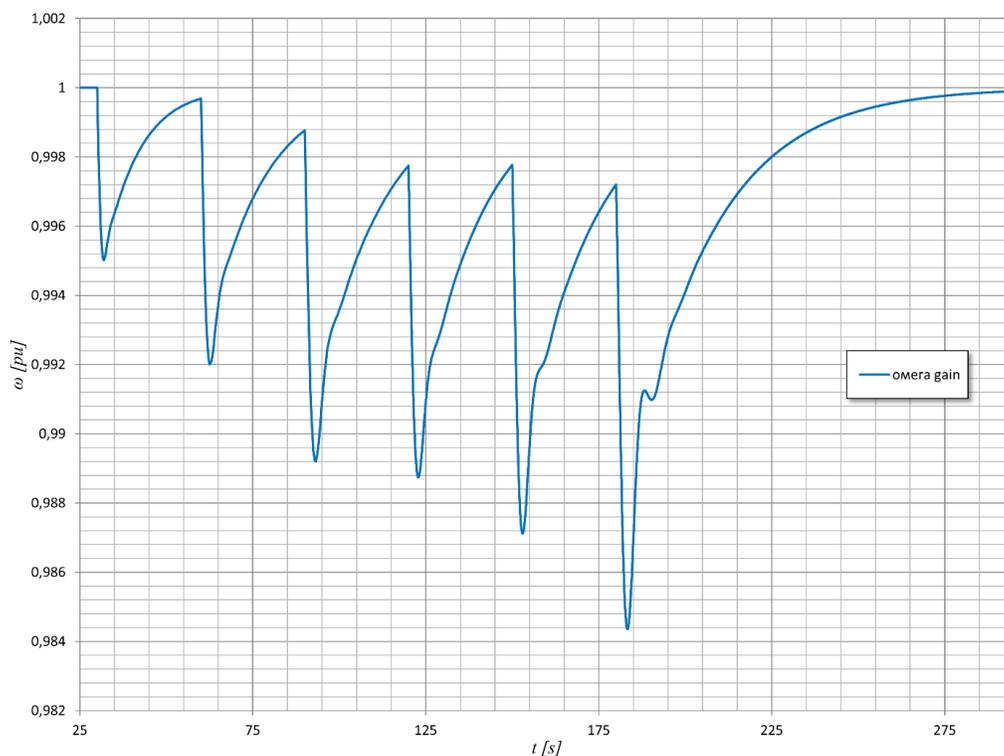
Слика 58. Одзив од нелинеарен модел без водостан и PID управување при црн старт [66]



Слика 59. Девиијација на фреквенцијата на нелинеарен модел без водостан со PID при црн старт [66]

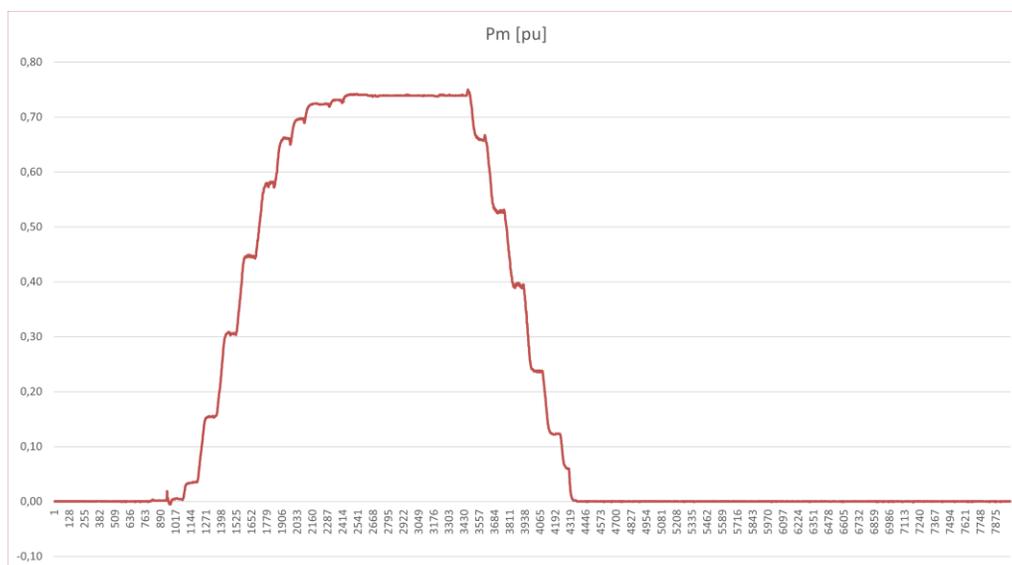


Слика 60. Одзив на нелинеарен модел без водостан и со распоред на засилувања на PID при црн старт [66]



Слика 61. Девијација на фреквенцијата на нелинеарен модел без водостан со распределување на засилувања на PID при црн старт [66]

На Слика 62 се претставени измерени податоци директно од хидроенергетски објект за излезната моќност при употреба на PID управување. Додека на Слика 63 се прикажани податоците превземени од SCADA системот за статичките карактеристики кои понатаму се користат како влезно податочно множество за обработка со ANN и ML.



Слика 62. Измерена излезна моќност при вклучување и исклучување на хидраулична турбина, податоци искористени за тренирање и валидирање на моделот од ML



Слика 63. Превземени податоци од SCADA системот за прва постројка

Согласно прикажаните резултати од симулациските модели и примената на ML кај хидроенергетски објект како објект на управување, најпрво преку споредување на Слика 31, Слика 32, Слика 33 и Слика 35, може да се каже дека примената на двојна техника на управување како комбинација на NARMA и PID, придонесува до подобрување на динамичките карактеристики на анализираниот објект на управување, додека пак само користење на NARMA техника на управување придонесува до тоа да во стационарна состојба се појавува грешка којашто не може да се елиминира. Тоа значи дека NARMA техниката на управување се однесува како чисто пропорционално управување. Тоа може да се случи од повеќе причини, една од нив е архитектурата на NN, изборот на големината на хиперпараметрите, квалитетот на податочното множество и неговата подготовка пред да се користи со алгоритмите на ML.

Дополнително, директното вметнување на NN во системот како замена за еден потсистем од целиот објект на управување, без притоа да се искористи техника на управување, согласно резултатите прикажани на Слика 37, може да се заклучи дека дава идеални резултати кои во реални работни услови не се случувај.

Во однос на примената на алгоритмите на ML за предвидување на вредностите на PID со цел подобрување на динамичките карактеристики на објектите на управување е претставено преку резултатите прикажани на Слика 41 до Слика 44. При тоа од големо значење е и архитектурата на NN, но и изборот на големините на хиперпараметрите.

Исто така согласно резултатите прикажани на Слика 39 и Слика 40, Слика 45 до Слика 52, може да се каже дека алгоритмите на ML, може да се користат и за идентификација на

систем. Во случајот на овој докторски труд е за одредување на вредности на временската константа на водата во цевководот, T_w преку која се одредува линеарниот модел на преносна функција на хидрауличната турбина. Истото важи и тука, дека во зависност од изборот на големините на хиперпараметрите, од алгоритмот, оптимизаторот но и квалитетот на податочното множество и тоа како е истото обработено, зависат и излезните резултати.

За да се формира дигитален близак за еден физички систем, од особено голема важност е квалитетот на податочното множество, но согласно прикажаните резултати, може да се каже дека е успешно изработен дигитален близак на хидроенергетски објект и истиот се користи за споредба на резултатите од одзивите од симулациски модели со резултатите од реални објекти на управување.

5 Глава 5 Верификација на примена на вештачки невронски мрежи и машинско учење

Со цел да се верифицираат презентираниите резултати од симулациите, во Лабораторијата за автоматика на Машинскиот факултет во Скопје беше составен модел, хидраулична инсталација којашто се состои од хидраулична пумпа која во воспоставениот систем беше во функција со притисок од 50 бари иако максималниот притисок што може да го постигне пумпата е 150 бари, вентил за ограничување на притисок, $4/3$ пропорционален распоредник од двете страни активиран со соленоид и пружини, хидрауличен цилиндар со двострано дејство и еднострана клипница, без дополнително надворешно оптоварување. Надворешно, дополнително оптоварување не беше поставено поради тоа што за цел на верификацијата не беше да се анализираат карактеристиките на хидрауличната инсталација при различни оптоварувања, туку да се види како и дали резултатите предвидени со примена на ML, може да се применат во реалноста на постоечка инсталација, а притоа колкаво ќе биде отстапувањето на измерените резултати добиени со симулација во споредба со реалните карактеристики на системот.

Алгоритамот на процесот за верификација на податоците добиени со примена на ML е следен:

1. Осознавање на системот којшто е потребно хардверски да се постави.
2. Воспоставување на хардверскиот дел на системот и поврзување на компонентите.
3. Анализа на параметрите кои влијаат на функционирањето на системот како што се: напон, проток, притисок, од на хидрауличниот цилиндар.
4. Поврзување на целиот систем со PLC.
5. Поставување (на хардверската инсталација) и поврзување на сензорот (на PLC) за мерење на позицијата на извлекување или вовлекување на клипот од хидрауличниот цилиндар.
6. Воспоставување комуникација помеѓу хардверскиот и софтверскиот дел.
7. Прилагодување на моделот во MATLAB/Simulink кон постоечката хардверска инсталација.
8. Се пишува скрипта во програмскиот јазик Python која со помош на ML ќе го обработи податочното множество, а потоа согласно внесените параметри ќе ги предвиди параметрите на PID управувањето.
9. Со помош на B&R Automation Studio Toolbox, изработениот модел во Simulink се претвора во Ц код, а потоа истиот код се префрла и обработува на PLC.
10. Добиените предвидени параметри за PID управувањето од ML, се внесуваат во PLC преку кој се изведува управувањето на извлекување/вовлекување на хидрауличниот цилиндар.
11. Се отчитуваат податоците измерени од сензорот и графички се претставуваат во Excel.
12. Истите добиени параметри се ставаат и во симулацискиот модел со цел да се споредат добиените резултати од симулација и добиените резултати од мерењето.

Со цел да се следи и мери позицијата на извлекување и вовлекување на клипот од хидрауличниот цилиндар, користен е линеарен сензор за мерење позиција и тоа Li300P0-Q25LM0-LIU5X3-H1151 од производителот TURCK.

За да се прикаже примената на различни методи на ML во реална примена, но во лабораториски услови, беше применета методата на брзо прототипирање. За да се примени таа метода, најпрво во MATLAB/Simulink беше изработен модел на хидрауличен систем, пропорционален вентил и хидрауличен цилиндар со двострано дејство и едностран клипница без надворешно оптоварување, прилагоден согласно параметрите и големините на компонентите достапни во Лабораторијата за автоматика на Машинскиот факултет во Скопје. При тоа резултатите од симулација и резултатите направени од мерењата, се споредени со цел да се направи верификација на резултатите добиени со примена на ML. За да се направи мерење на резултатите во реално време, се користи методата на real time control prototyping. Пресметката на симулацијата за хидрауличната инсталација (хидрауличен цилиндар и пропорционален распоредник) се врши со брзина на семплирање од 0,01 секунда. Симулацијата е изработена во софтверскиот пакет MATLAB/Simulink. Дефинирањето на референтната позиција односно поместот на клипот од хидрауличниот цилиндар зависи од константите добиени од примената на ML.

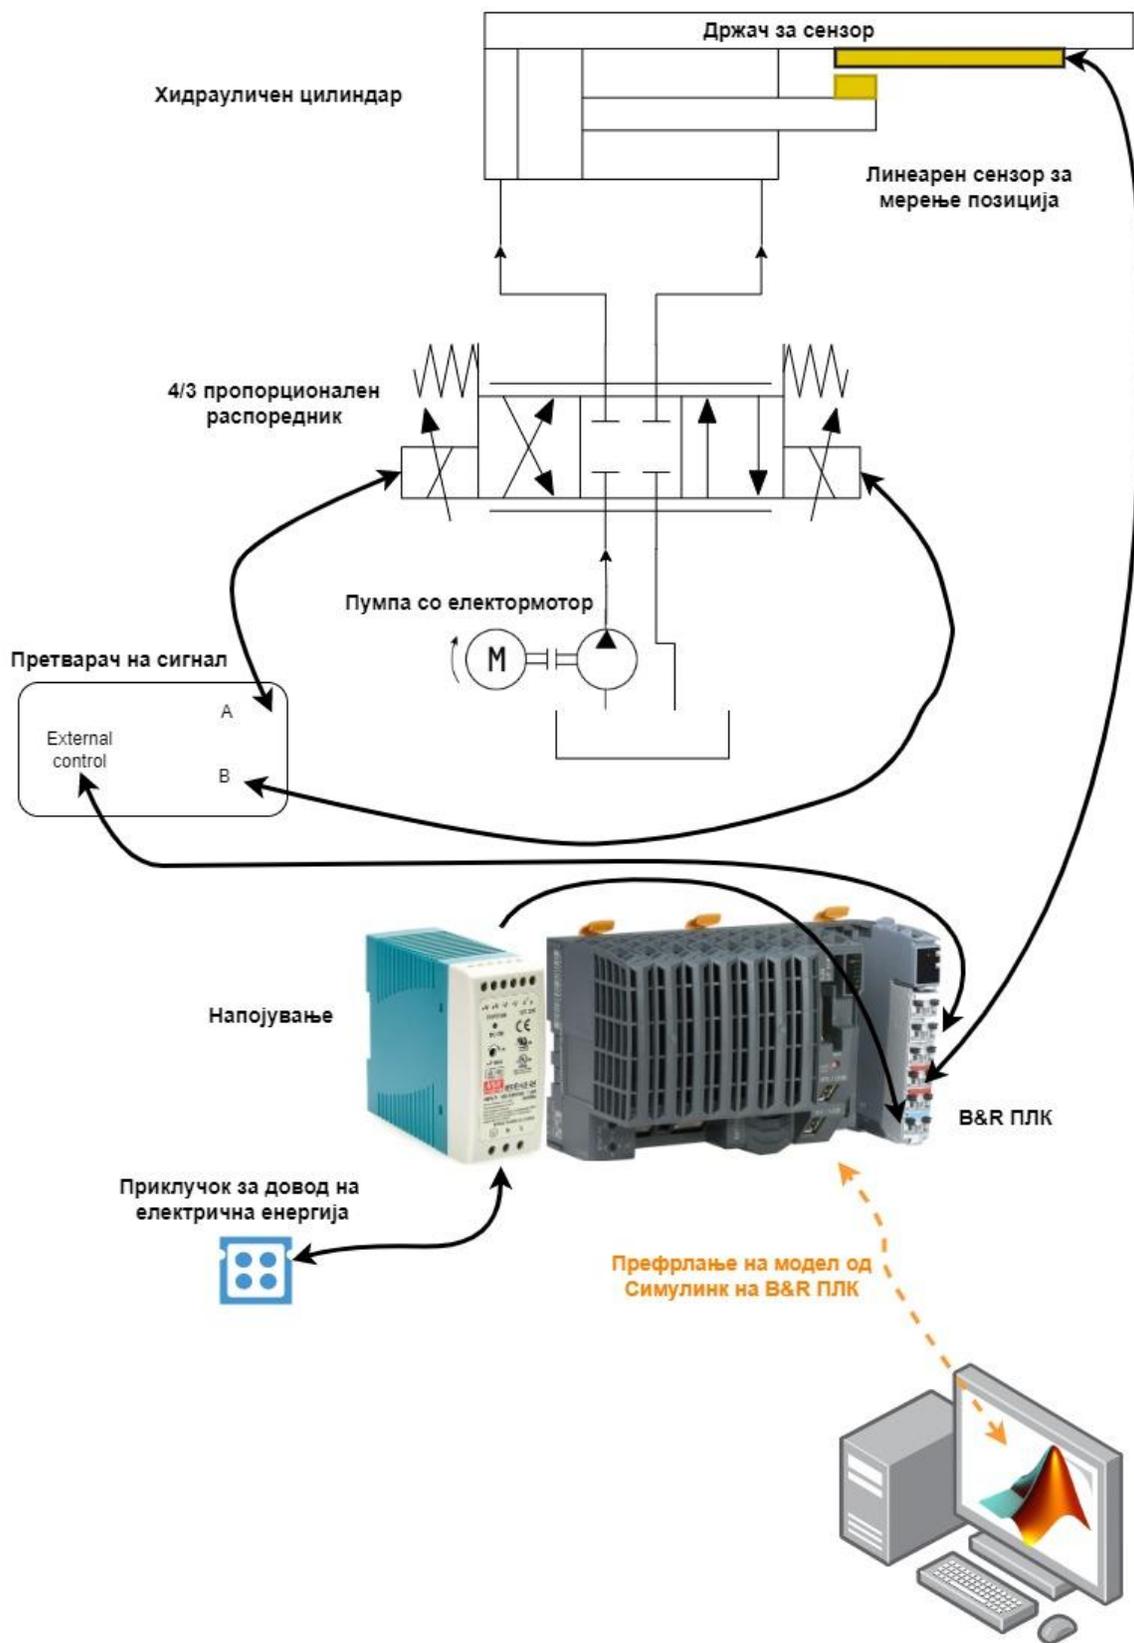
Примена на методата за пресметка и добивање на резултатите во реално време за верификација на управувачкиот сигнал опфаќа примена на софтверот MATLAB/Simulink во кој е симулиран процесот на извлекување и вовлекување на хидрауличен цилиндар управуван од страна на пропорционален 4/3 вентил. Бидејќи пропорционалниот распоредник од двете страни е активиран со соленоид, напонот којшто се доведува на соленоидот е $\pm 10\text{ V}$. Тоа значи дека со доведување на напон од -10 V до 0 V , ќе го активира соленоидот А, односно ќе се изведува фазата на извлекување, додека со доведување на напон од 0 V до $+10\text{ V}$, ќе се активира соленоидот Б, односно ќе се изведува фазата на вовлекување.

Првичната идеја беше да се искористи управување засновано на NN и управувачкиот сигнал од него да се преслика на хидрауличната инсталација. Но со достапниот хардвер во Лабораторијата за автоматика на Машинскиот факултет во Скопје, не беше возможно да се преслика моделот на управување засновано на NN поради застареноста на опремата, па затоа искористена беше опцијата со предвидување на константите на PID управување и нивно вметнување во PLC со цел управување на извлекување и вовлекување на клипот од хидрауличниот цилиндар којшто симулира отворање и затворање односно поместување на лопатките од спроводниот апарат.

За да може во реално време да се реализира верификација на вредностите на PID добиени со ML, беше искористен PLC тип B&R XC20 CP 1485. Освен процесорот, беа искористени и аналогни влезови AI 4622 за да може да се поврзе сензорот за мерење позиција и аналогните излези AO 4622 за да може да се реализира доведувањето на напон на еден од соленоидите А или В со цел извлекување или вовлекување.

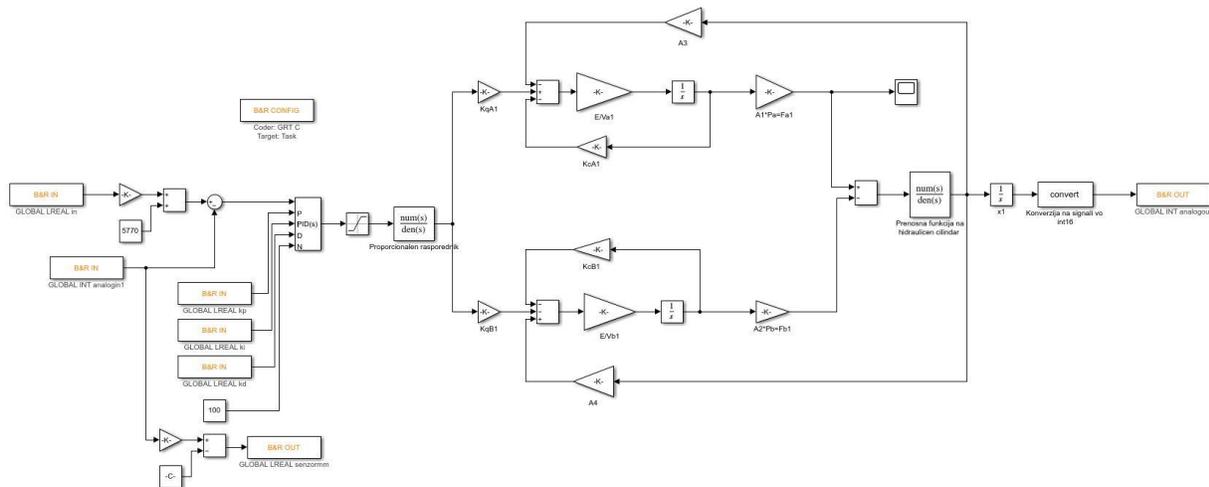
Изработениот модел во MATLAB/Simulink е искористен со цел да се споредат измерените одзиви со одзивите од симулација и да се добие процентуално за колку се разликуваат тие помеѓу себе со цел да се направи верификација на вредностите добиени со помош на ML.

На Слика 64, сликовито е претставена шема на целокупната инсталација составена од хидрауличен цилиндар со двострано дејство и еднострана клипница, 4/3 пропорционален распоредник, пумпа, сензор за мерење на позиција, претвораач на сигнал и PLC.



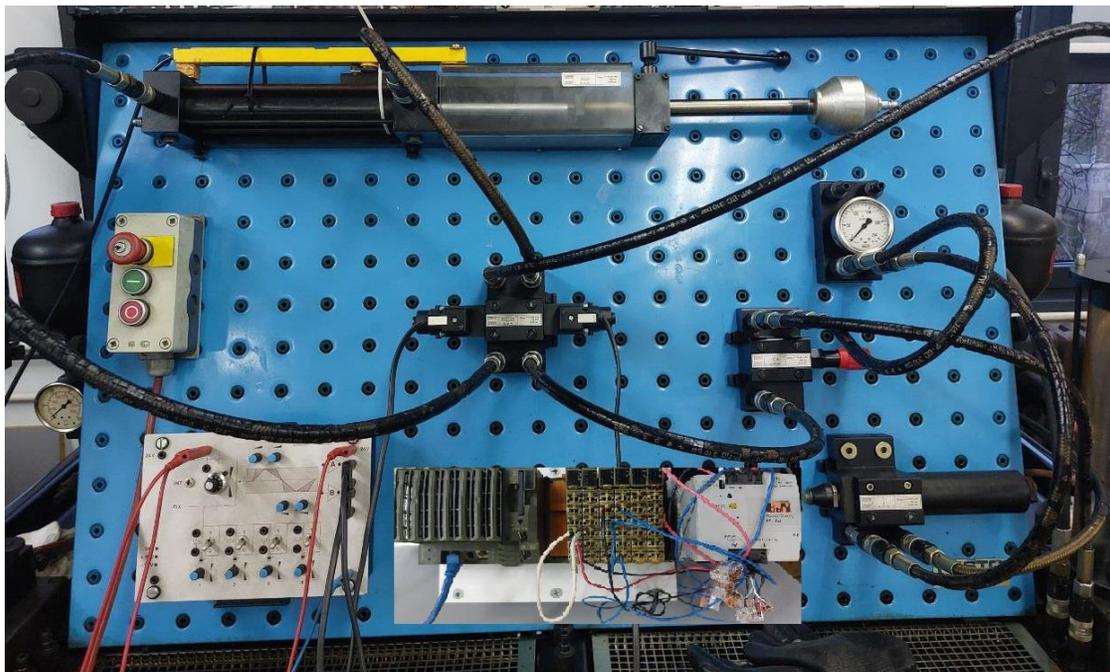
Слика 64. Шема на хидрауличната инсталација во Лабораторијата за автоматика

На Слика 65 претставен е моделот изработен во MATLAB/Simulink којшто се користи за реализирање на методата на брзо прототипирање (real-time control prototyping) на хидраулична инсталација составена од хидрауличен цилиндар и пропорционален 4/3 распоредник за пресметување во реално време, а со тоа и анализа на влијанието на константите од PID управувањето добиени со примена на ML.



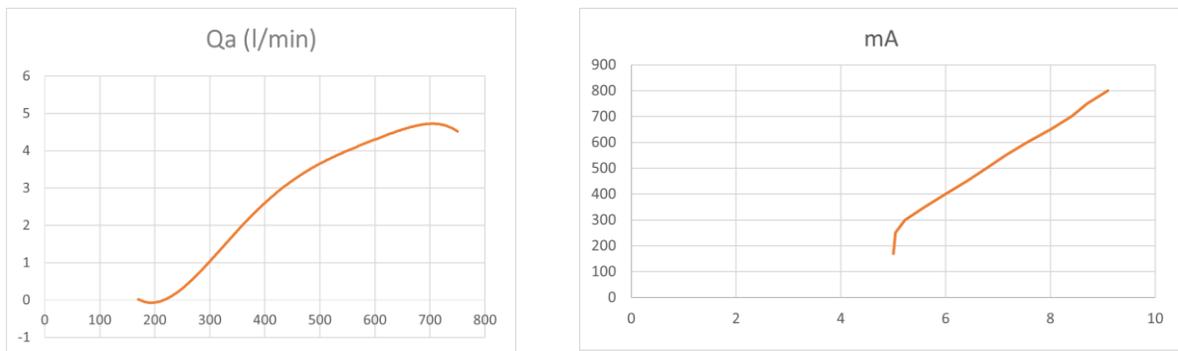
Слика 65. Модел на хидраулична инсталација изработена во MATLAB/Simulink подготвена за пресметка во реално време со помош на B&R Automation Studio Toolbox

На Слика 66 е претставен физичкиот модел за симулирање на спроводниот апарат преку која ќе се направи верификација на резултатите од ML.

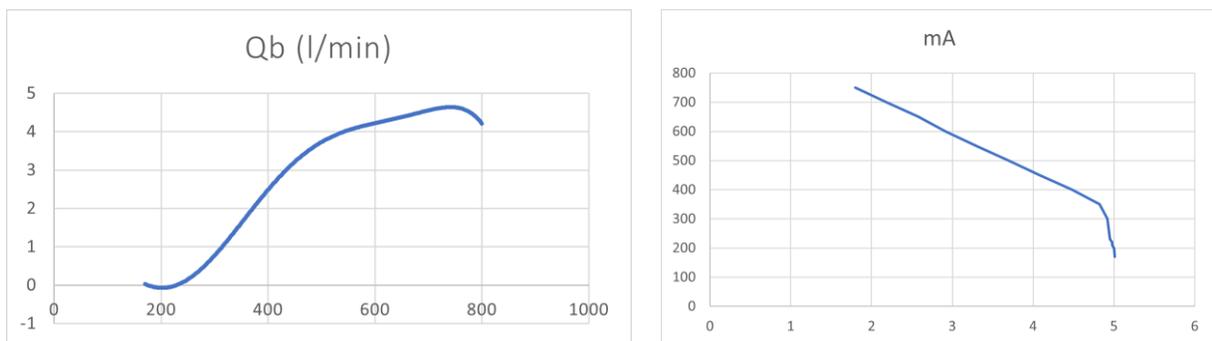


Слика 66. Лабораториска инсталација за верификација на резултатите од машинското учење

Најпрво беше направено мерење на карактеристиката на распоредникот за неговите два соленоиди, А и Б. Преку карактеристиката на распоредникот беше утврдено како се менува протокот во однос на доведениот напон или струја. Карактеристиката на распоредникот е прикажана на Слика 67 и Слика 68. Исто така преку повторување на мерењето беше увидено дека кривата на распоредникот не е константно иста во моментот кога хидрауличната инсталација е вклучена и после одредено време (10-20 минути) работа. Се претпоставува дека причина за појава на разлика во карактеристиката на распоредникот е поради тоа што после одредено време, кога температурата на хидрауличното масло ќе ја достигне нормалната работната температура ($40 \div 50^\circ \text{C}$), пумпата започнува да испушта гласни и нестандартни звуци. Поради потврдување на наведената претпоставка, во иднина е потребно да се направат детални мерења и анализи за да се види колку промената на температурата на хидрауличното масло влијае на карактеристиката на распоредникот и пумпата и колку таа промена влијае на перформансите на системот. Доколку се спореди средната вредност на мерењата за струја во однос на протокот и напонот во однос на струјата, може да се каже дека разликата на кривата е околу 20%. Таквата разлика ќе биде земена во предвид кога ќе се анализираат одзивите при верификација на резултатите кои ќе бидат презентирани за различни предвидени вредности добиени со помош и примена на методите на ML.



Слика 67. Карактеристика на распоредник за соленоид А



Слика 68. Карактеристика на распоредник за соленоид Б

За да може да се споредат податоците од мерење и податоците од симулациските модели, најпрво е потребно да се оформи податочно множество за влезните и излезните параметри со чија помош ќе се тренира моделот на ML. За таа цел создадено е податочно множество каде што како влез во NN влегуваат напонот и отвореноста на спроводниот апарат, додека

на излез од NN се поставени параметрите на PID управувањето, Kp, Ki и Kd. Тие се генерирани во голем опсег со цел да и се овозможи на мрежата да направи најсоодветно предвидување на различни комбинации на константите кои понатаму ќе бидат применети за верификација. Притоа се добиени голем број на податоци со различни карактеристики во самата мрежа.

Добиените предвидени вредности за новите константи на PID управувањето се прикажани во Табела 12.

Табела 12. Податоци добиени за константите на PID управувањето со различна конфигурација на невронската мрежа

Ред. Бр.	Kp	Ki	Kd	слоеве	AF во слој 1	AF во слој 2	AF во слој 3	епохи	брзина на учење
1	471	328	476	2 200 102 3	tanh	sigmoid	relu	500	0,01
2	692	425	576	3 200 102 3	tanh	sigmoid	relu	500	0,01
3	160	159	162	2 20 12 3	tanh	tanh	tanh	500	0,01
4	471	328	476	2 20 12 3	sigmoid	sigmoid	relu	500	0,01
5	76	75	76	2 5 3	sigmoid	sigmoid		500	0,01
6	31	31	32	3 5 3	tanh	tanh		200	0,01
7	150	148	153	3 5 3	tanh	tanh		1000	0,01
8	472	327	475	3 50 12 3	tanh	tanh	relu	1000	0,01
9	472	327	475	3 50 12 3	tanh	tanh	relu	1000	0,1
10	472	327	475	3 50 12 3	tanh	tanh	relu	1000	0,1
11	471	326	475	3 50 12 3	tanh	tanh	relu	1000	0,01
12	267	261	267	3 50 12 3	tanh	tanh	sigmoid	1000	0,01
13	26	25	28	3 50 12 3	tanh	tanh	sigmoid	100	0,01
14	139	135	140	3 50 3	tanh	tanh		100	0,01
15	139	137	138	3 50 3	tanh	tanh		100	0,01
16	141	133	138	3 50 3	tanh	tanh		100	0,1
17	472	326	475	3 50 3	tanh	tanh		1000	0,1
18	472	326	475	3 50 3	sigmoid	sigmoid		1000	0,1
19	472	326	475	3 50 3	sigmoid	sigmoid		1000	0,001
20	254	235	254	3 50 3	sigmoid	tanh		200	0,001
21	50	51	54	3 50 12 3	sigmoid	tanh	sigmoid	200	0,001
22	47	46	46	3 50 12 3	sigmoid	tanh	sigmoid	200	0,01
23	39	37	37	3 50 12 3	sigmoid	tanh	sigmoid	200	0,01
24	304	291	308	3 50 12 3	sigmoid	tanh	sigmoid	1000	0,001
25	314	298	315	3 50 12 3	sigmoid	tanh	tanh	1000	0,001

Од Табела 12 може да се види дека со примена на ML при различни конфигурации на NN, а при различен број на епохи (колку пати податочното множество се пресметува низ

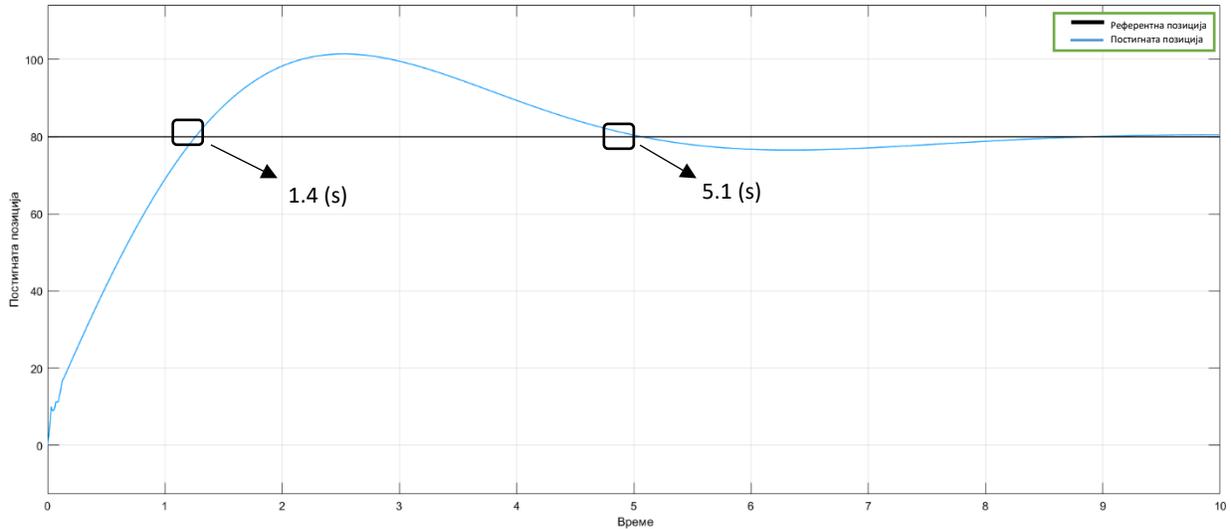
алгоритамот за оптимизација пред да се добие финалниот излезен резултат од ML) и брзина на учење, се добиваат различни константи за PID управувањето. Притоа од табелата може да се види дека во дел од моделите на NN се користат два скриени слоја, а во дел се користат три скриени слоја. Исто така бројот на епохи се менува од 100 до 1000, брзината на учење се менува од 0,1 до 0,001. Согласно прегледаната литература, не постои еднозначен начин на пресметка на бројот на епохи, бројот на скриени слоеви и вредноста на брзината на учење. Тие се прилагодуваат интуитивно во однос на големината на податоците со кои се работи и врз основа на динамиката на системот. Пресметувањето на константи во широк спектар на вредности согласно табелата е поради тоа што на самата NN и беше дадено податочно множество со широк опсег на вредности со можност на тренирање, валидирање и предвидување резултати. Исто така од табелата може да се забележи дека во скриените слоеви, бројот на неврони се менува од 5, 20, 50, 200 кое што понатаму при анализа на добиените резултати ќе се види дека имаат важна улога при предвидувањето на константите на PID. Оние редици што се означени со црвена боја, се вредностите на параметрите на PID кои потанаму се користат при симулација и експеримент со цел верификација на резултатите. При анализа на изборот на хиперпараметри и конфигурација на NN презентирани во Табела 12, а согласно претходната анализа на влијанието на хиперпараметрите и конфигурацијата на NN опишани во поглавје 4.6, може јасно да се каже зошто тие се избрани, а воедно даваат и најсоодветни резултати при анализа на одзивите од симулација и од експерименталните мерења. Согласно конфигурацијата на мрежата за резултатите од редица број 1 и 2, бидејќи AF во последното слој е relu, поради нејзината незаситена природа, овозможува побрзо учење и конвергирање кон глобален минимум, а во комбинација со ниска вредност на брзина на учење (0,01) како што е пример тука, но и соодветен број на епохи, се обезбедува брзо конвергирање кон минимум и брзо учење. Истото важи и за вредностите добиени во редица број 10. Но бидејќи тука има поставено помала брзина на учење (0,1) и 1000 број на епохи во комбинација со tanh/tanh/relu исто обезбедуваат брзо конвергирање и учење. Во однос на резултатите од редица број 24, каде што поставеноста на AF е sigmoid/tanh/sigmoid е нестандартна бидејќи поради појавата на sigmoid во последниот слој може да предизвика губење на градиентите и доведување до состојба на overfitting.

Согласно Табела 12, означените редици со црвено се вредностите за PID константите кои даваат најсоодветни резултати. Во продолжение ќе бидат презентирани и резултати од симулациските модели, но и од мерењата.

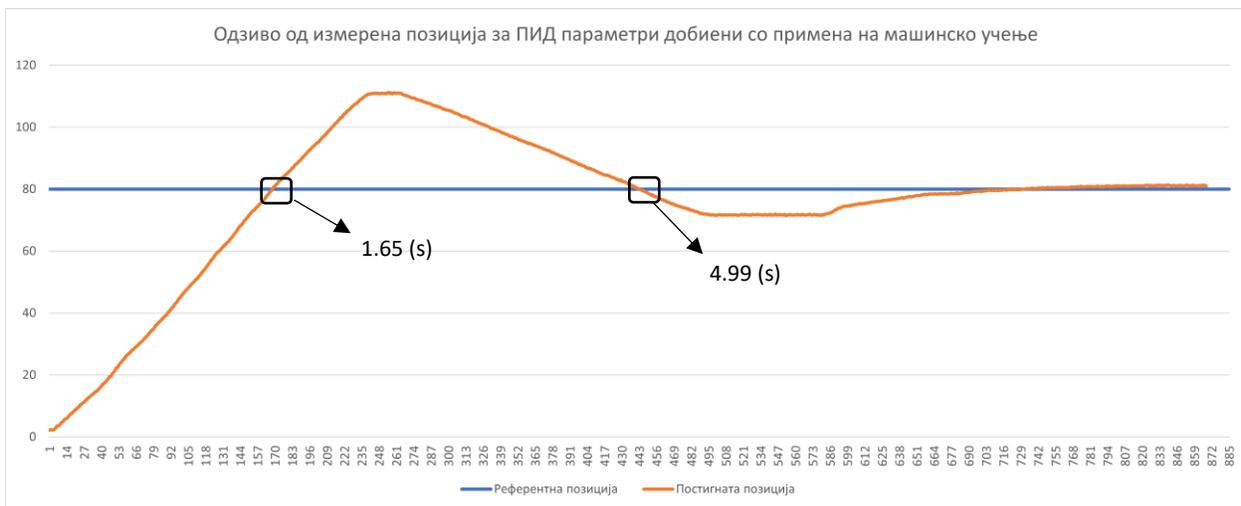
За да може да се направи верификација односно споредливост, се одредува средната процентуална разлика помеѓу одзивите добиени со симулација и вистински добиените одзиви. За таа цел се користи равенка 68. Во оваа равенка со a се означуваат вистинските вредности, со p се означени вредностите добиени од симулација и со n се означуваат бројот на примероци.

$$MPE = \frac{1}{n} \cdot \sum \left(\frac{a-p}{a} \right) \cdot 100 \quad (68)$$

Првата група резултати се со предвидени PID за $K_p=304$, $K_i=291$ и $K_d=308$ со NN со два скриени слоја. Првиот скриен слој е составен од 50 неврони, вториот скриен слој е составен од 12 неврони и излезниот слој е составен од три неврони односно трите константи што треба да се предвидат. AF во првиот слој е sigmoid, AF во вториот слој е tanh, излезниот слој е sigmoid. Брзината на учење е 0,001 и бројот на епохи е 1000. Доколку референтната вредност се постави да биде 80 мм, односно клипот од хидрауличниот цилиндар да се извлече на растојание од 80 мм и да ја задржи таа состојба тогаш NN согласно достапните податоци, ги предвиде вредностите на PID управувањето, $K_p=304$, $K_i=291$ и $K_d=308$. Одзивите согласно зададените параметри се преставени на Слика 69 и Слика 70.



Слика 69. Одзив од симулација за поместување на позиција 80 мм

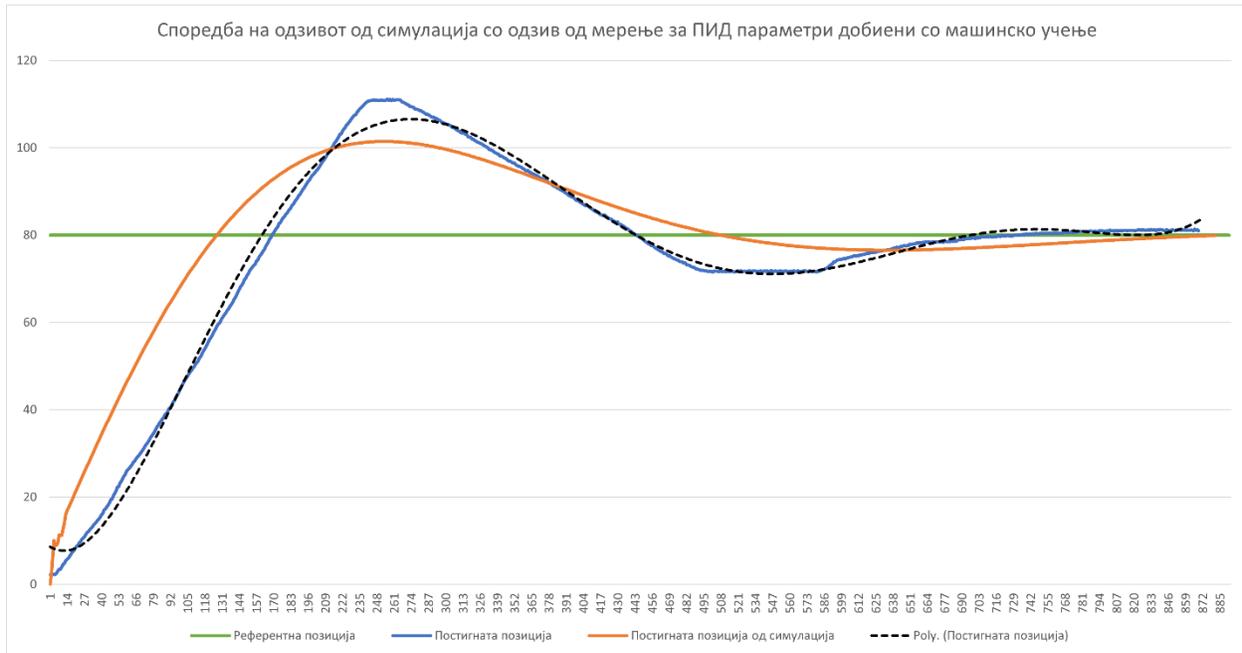


Слика 70. Одзив од измерено поместување на позиција 80 мм

Разликата којашто се појавува помеѓу симулацискиот модел и извлекувањето измерено со сензор при постигнување стационарна состојба е 16 %, а при постигнување на референтна позиција е речиси 2 % разлика.

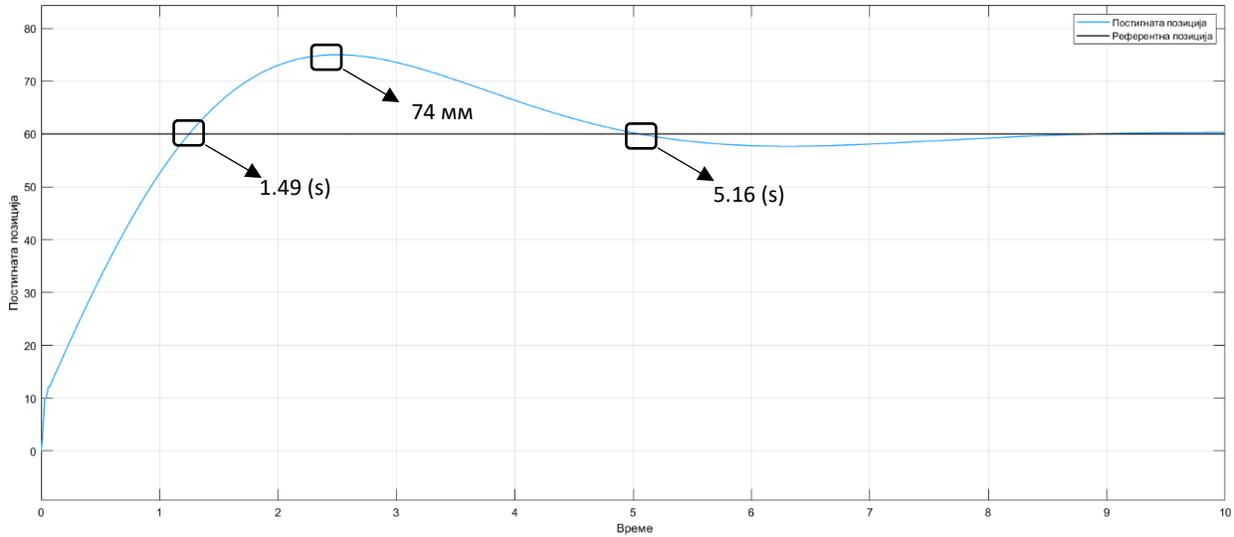
Средната квадратна грешка помеѓу одзивите е 7 додека квадратен корен од средната квадратна грешка е 2.6. Доколку се пресмета средната процентуална грешка помеѓу вистинскиот и одзивот добиена на симулација, се добива 5 % разлика.

За полесна споредба на одзивите од симулација и добиени од мерење на Слика 71 се претставени одзивите преклопени со цел полесно да се забележи разликата.

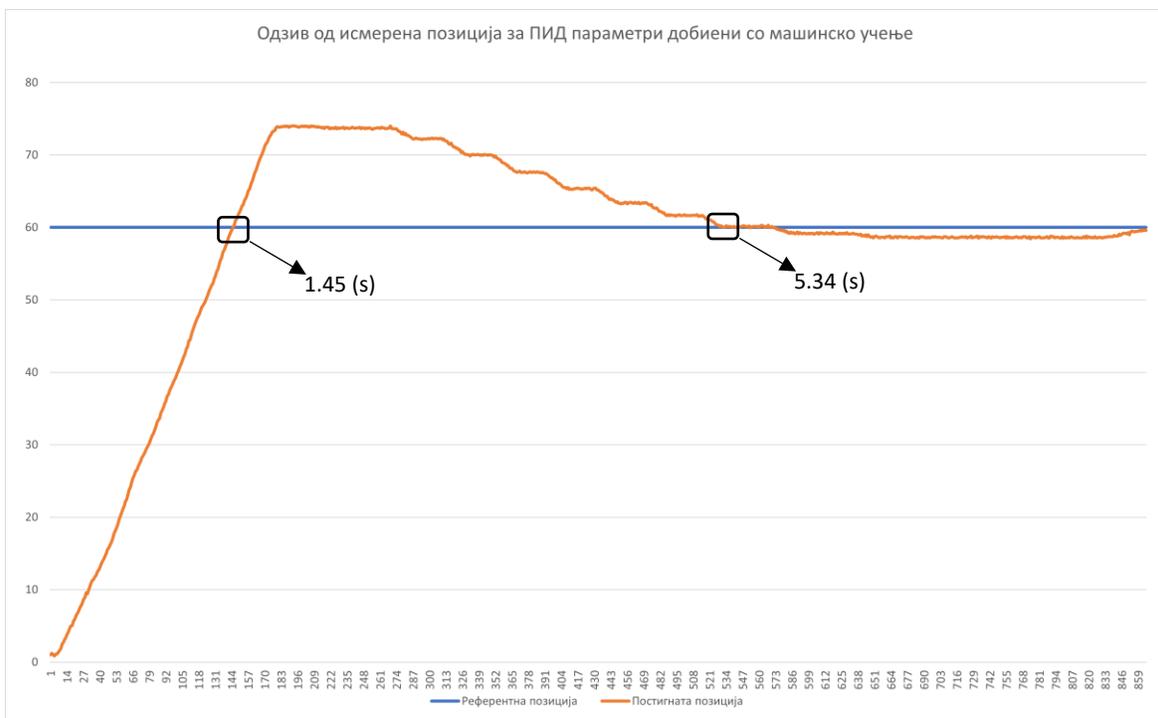


Слика 71. Споредба на одзивите од симулација и одзивите од мерење за прва група резултати за поместување на позиција 80 мм за $K_p=304$, $K_i=291$ и $K_d=308$

Втората група резултати се со предвидени PID за $K_p=475$, $K_i=327$ и $K_d=472$ со NN со два скриени слоја. Првиот скриен слој е составен од 50 неврони, вториот скриен слој е составен од 12 неврони и излезниот слој е составен од три неврони односно трите константи што треба да се предвидат. AF во првиот слој е tanh, AF во вториот слој е tanh, излезниот слој е relu. Брзина на учење е 0,1 и бројот на епохи е 1000. Доколку референтната вредност се постави да биде 60 мм, односно клипот од хидрауличниот цилиндар да се извлече на растојание од 60 мм и да ја задржи таа состојба тогаш NN согласно достапните податоци, ги предвиди вредностите на PID управувањето, $K_p=475$, $K_i=300$ и $K_d=472$. Одзивите согласно зададените параметри се претставени на Слика 72 и Слика 73.

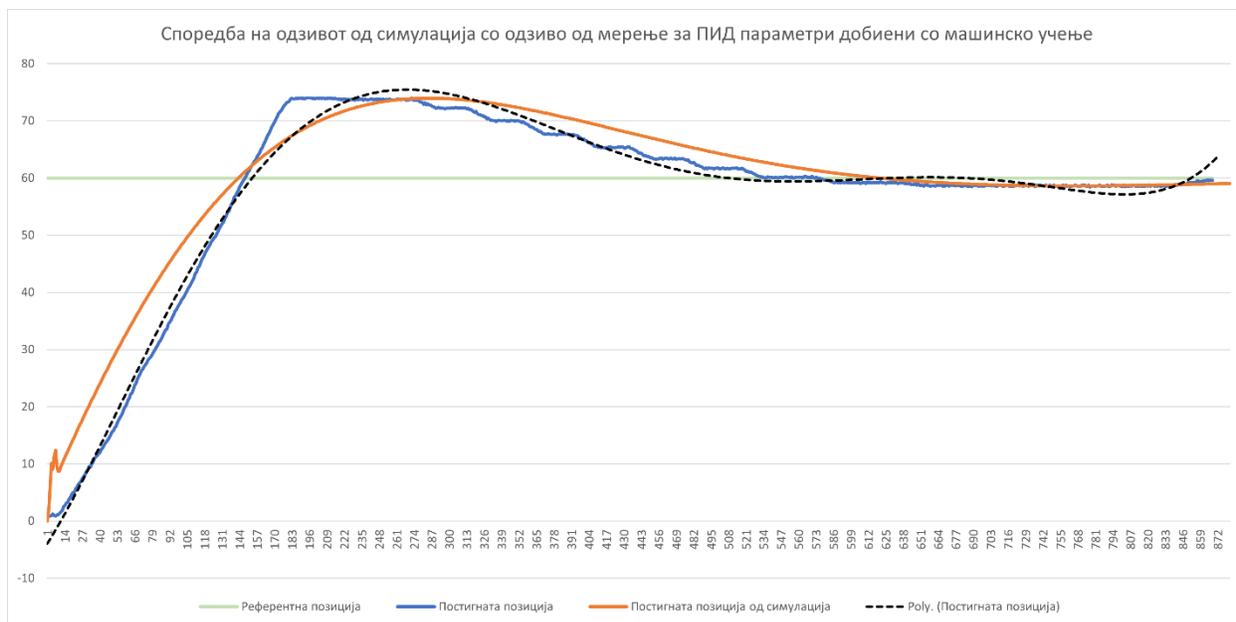


Слика 72. Одзив од симулација за поместување на позиција 60 мм за $K_p=475$, $K_i=327$ и $K_d=472$



Слика 73. Одзив од измерено поместување на позиција 60 мм за $K_p=475$, $K_i=327$ и $K_d=472$

На Слика 74 е претставена споредба на одзивите направени од симулација и одзивите од мерење за втората група резултати со цел нивна споредба при верификација.

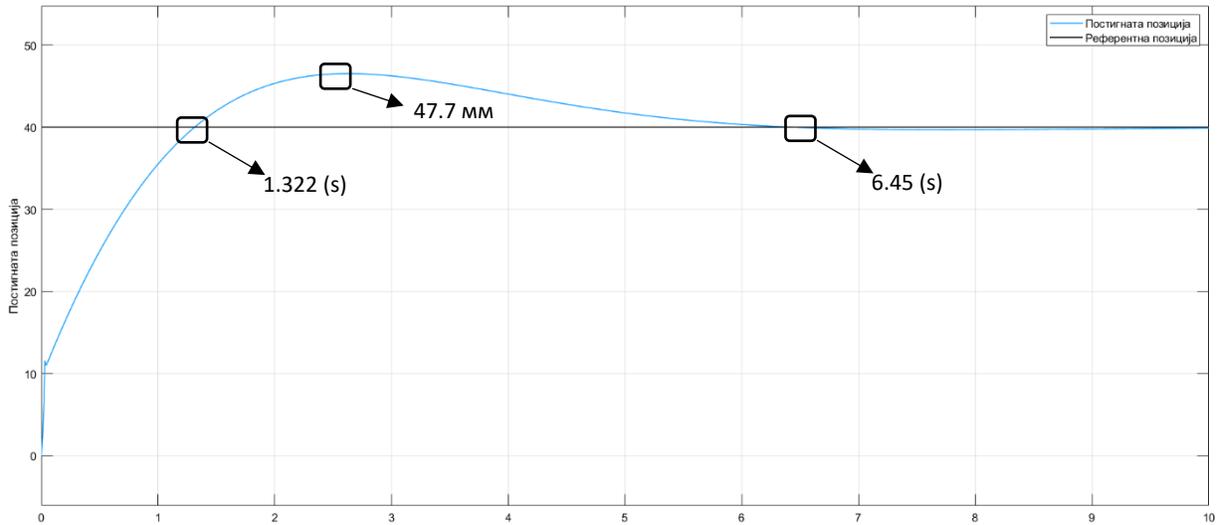


Слика 74. Споредба на одзивите од симулација и одзивите од мерење за втора група резултати за поместување на позиција 60 мм за $K_p=475$, $K_i=327$ и $K_d=472$

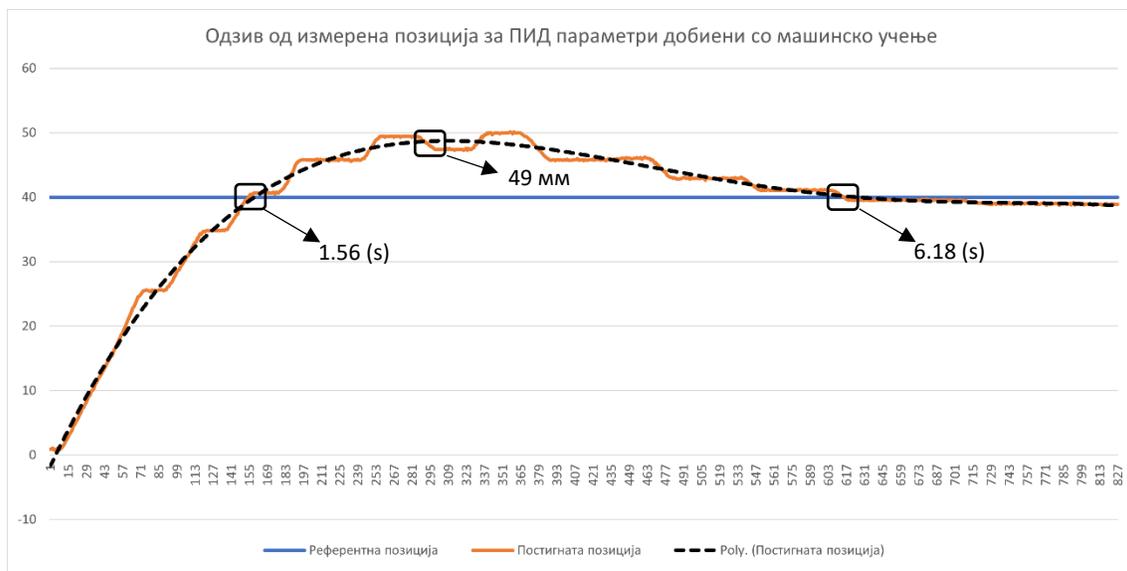
Разликата којашто се појавува помеѓу симулацискиот модел и извлекувањето измерено со сензор при постигнување на референтна позиција е 2 %. Во однос на точката на достигнување на стационарна состојба разликата е поголема од 3.4 %.

Средната квадратна грешка помеѓу одзивите е 2.3, додека квадратен корен од средната квадратна грешка е 1.5. Доколку се пресмета средната процентуална грешка помеѓу вистинскиот и одзивот добиен на симулација, се добива 3.7 % разлика.

Третата група резултати се со предвидени PID за $K_p=690$, $K_i=425$ и $K_d=576$ со NN со два скриени слоја. Првиот скриен слој е составен од 200 неврони, вториот скриен слој е составен од 102 неврони и излезниот слој е составен од три неврони односно трите константи што треба да се предвидат. AF во првиот слој е \tanh , AF во вториот слој е sigmoid , излезниот слој е relu . Брзина на учење е 0,01 и бројот на епохи е 500. Доколку референтната вредност се постави да биде 40 мм, односно клипот од хидрауличниот цилиндар да се извлече на растојание од 40 мм и да ја задржи таа состојба тогаш NN согласно достапните податоци, ги предвиде вредностите на PID управувањето, $K_p=690$, $K_i=425$ и $K_d=576$. Одзивите согласно зададените параметри се преставени на Слика 75 и Слика 76.

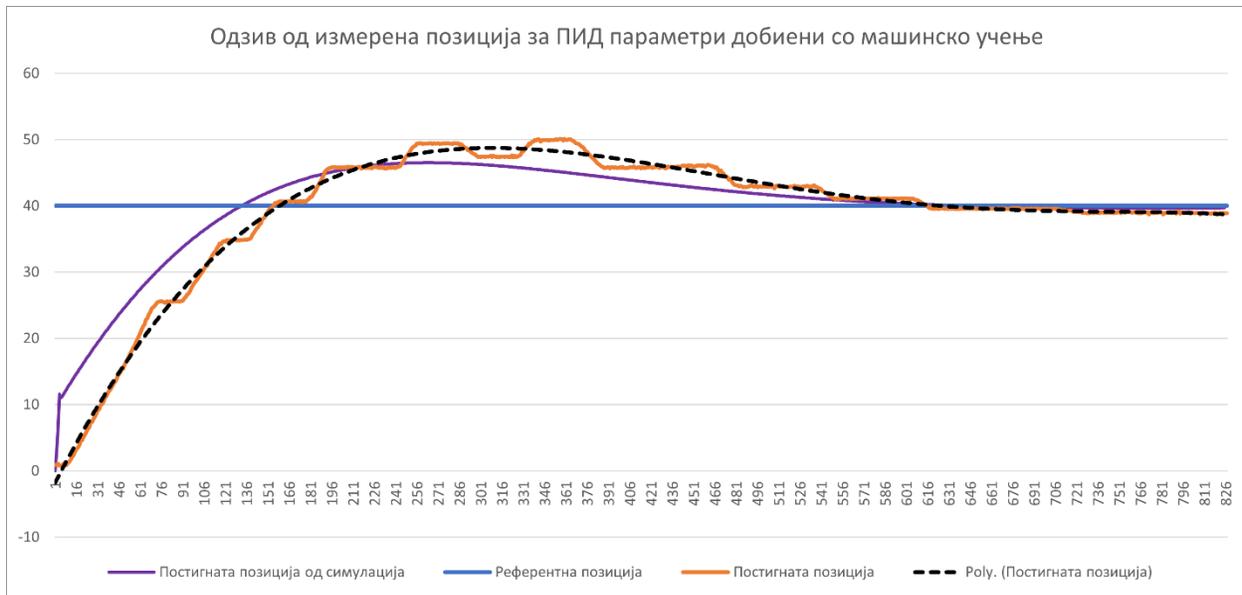


Слика 75. Одзив од симулација за поместување на позиција 40 мм за $K_p=690$, $K_i=425$ и $K_d=576$



Слика 76. Одзив од измерено поместување на позиција 40 мм за $K_p=690$, $K_i=4425$ и $K_d=576$

На Слика 77 претставена е споредба на одзивите направени од симулација и одзивите од мерење за третата група резултати со цел нивна споредба при верификација.



Слика 77. Споредба на одзив од мерење и симулација за поместување на позиција 40 мм со $K_p=690$, $K_i=4425$ и $K_d=576$

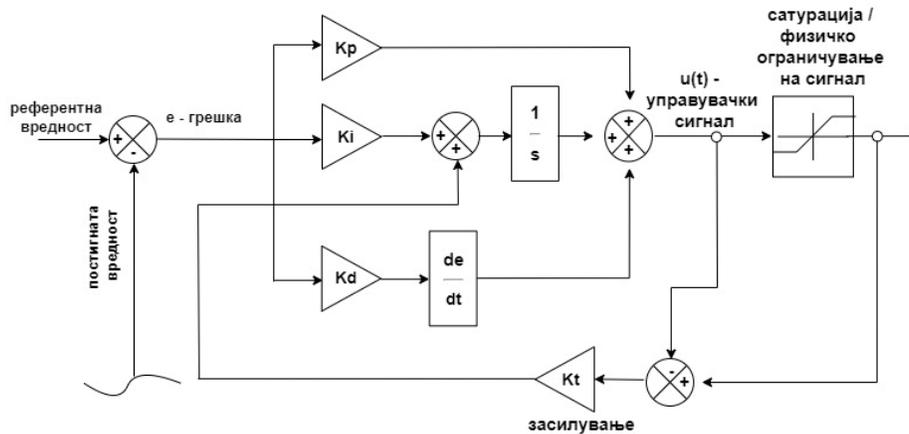
Разликата којашто се појавува помеѓу симулацискиот модел и извлекувањето измерено со сензор при постигнување на референтна позиција е 17 %. Во однос на точката на достигнување на стационарна состојба разликата е поголема од 4.3 %.

Средната квадратна грешка помеѓу одзивите е 0.15, додека квадратен корен од средната квадратна грешка е 0.4. Доколку се пресмета средната процентуална грешка помеѓу вистинскиот и одзивот добиена на симулација, се добива 1.4 % разлика.

Согласно прикажаните и анализирани резултати, може да се каже дека брзината на учење која се менува од 0,1 до 0,001, сама по себе нема големо влијание при предвидувањето на константите на PID управувањето. Голема улога игра бројот на епохи бидејќи како што беше претходно објаснето, тоа е вкупниот број на поминување на целото податочно множество низ NN, па од тука зависи квалитетот на добиениот одзив. Но тоа не значи дека бројот на епохи треба да биде енормно голем бидејќи тоа може да доведе до претренирање на NN што исто така доведува до несоодветни резултати. Освен тоа голема и важна улога, конкретно за предвидување на PID константите за управување на извлекување и вовлекување на хидрауличниот цилиндар, играат типовите на AF и нивна распределба во NN. Исто толку важна улоги при добивање на резултатите и при предвидување на вредностите е бројот на скриени слоеви и бројот на неврони сместени во секој од скриените слоеви. Како главен заклучок од споредбата на одзивите, може да се каже дека архитектурата на NN со редоследно поставени AF, но и соодветен број на епохи, неврони и скриени слоеви има многу голема улога при добивањето на одзив со најмала процентуална грешка при симулираните и одзивите добиени од мерење. Како што може да се види и од Табела 12, распределеноста и поставеноста на параметрите на NN се најсоодветни за третата група одзиви, а тоа може да се види и при споредбата на одзивите и процентуалната разлика.

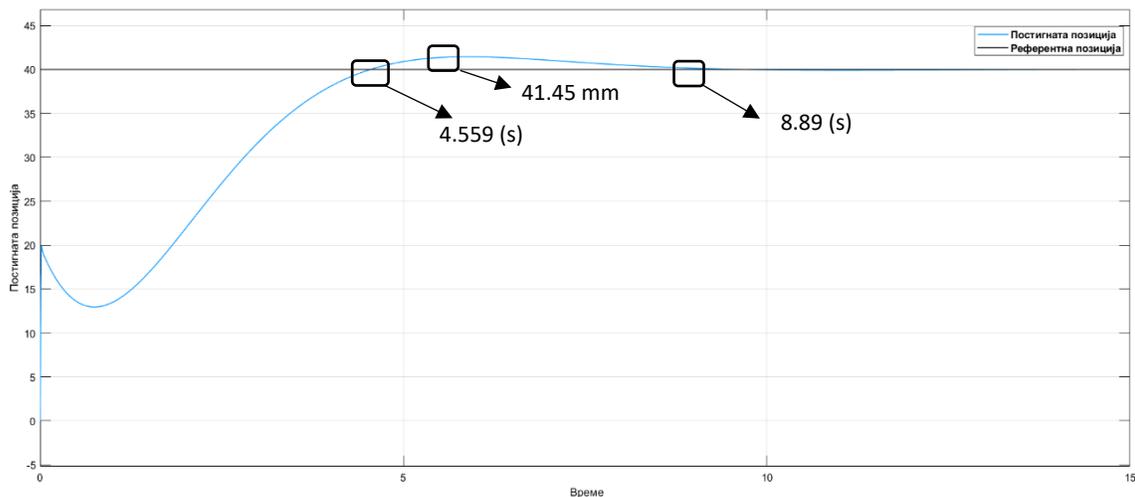
На измерените одзиви, но и на одзивите преземени од симулациските модели за извлекување на клипот од хидрауличниот цилиндар до соодветна позиција, прикажани на Слика 69 до Слика 77, може да се забележи голем прескок. Тој голем прескок се појавува како резултат на последиците од постоењето на заситување за физички ограничување на сигналите во системот. Како последица од постоењето на заситување во системот се појавува тој голем прескок, а тој феномен е познат како интегрален побег. Тоа се појавува поради наглите промени на референтната вредност, односно вредноста којашто системот треба да ја постигне како референтна, а со тоа настанува акумулирањето на грешка во интегралната константа која понатаму интегралната константа се множи со интеграл од грешката, но по поголем временски период поради тоа што периодот на акумулирање на грешката е поголем. Доколку се помали промените во референтната вредност од една во друга состојба, во тој случај прескокот би требало да биде помал. Една од методите за справување со овој феномен којшто се појавува кај PID управувањето поради влијание на постоењето на заситување е anti-windup метода која може да го реши проблемот на повеќе различни начини, а две најпопуларни методи за нивно решавање е clamping методата којашто овозможува исклучување на интегралниот дел од управувањето со цел да се справи системот со големите прескокнувања кои се појавуваат поради влијанието на заситувањето, друг исто така популарен метод е back-calculation anti-windup кој овозможува доведување на дополнителна повратна врска после интегралната константа од PID управувањето односно се носи сигнал како резултат на разликата пред и после заситувањето. Тој сигнал се засилува и се собира со интегралната константа, па така на тој сигнал се пресметува интеграл, како што е прикажано на Слика 78. Овие се можни начини на справување со влијанието на заситувањето врз PID управувањето. Во овој докторски труд ќе биде презентирани back-calculation anti-windup начинот на справување со влијанието на сатурацијата врз PID управувањето.

Согласно Табела 12 може да се забележи дека вредностите добиени со примена на ML кај речиси сите комбинации, интегралната константа има помала вредност во зависност од пропорционалната или диференцијалната. Тоа би можело да значи дека ML при самото генерирање на комбинациите прави проба за елиминирање, односно намалување на интегралната константа. Претпоставка е дека "несвесно ML се бори" со феноменот интегрален побег, но сепак се покажува дека во зависност од достапната база со податоци, ML како што се бори со тој феномен, исто така "несвесно" системот го доведува до таа фаза поради предвидениот сет на пропорционалната, интегралната и диференцијалната константа. Примената на методот на back-calculation anti-windup, доведува до состојба да системот ја намали брзината на достигнување на бараната референтна позиција, но за таа цел се намалува прескокот на системот. Примената на оваа метода со блок дијаграм е прикажана на Слика 78. Согласно прикажаниот блок дијаграм направени се симулациски испитувања во MATLAB/Simulink со цел да се потврди приложената метода за подобрување на динамичките карактеристики на системот. Но истиот модел преку Automation Target Studiot е пресликан и во B&R PLC со цел да се верифицира предложената метода. Резултатите се прикажани на Слика 79 до Слика 90.



Слика 78. Блок дијаграм на методата back-calculation

Добиените одзиви од симулација изработени во MATLAB/Simulink се презентирани преку третата група резултати каде што $K_p=690$, $K_i=425$ и $K_d=576$, а согласно одзивот од Слика 75 најголемиот прескокот се појавува на позиција 47.7 мм. Со воведување на back-calculation методата за намалување на влијанието на заситувањето на интегралниот член од PID управувањето, се добива одзивот во MATLAB/Simulink како што е прикажан на Слика 79.

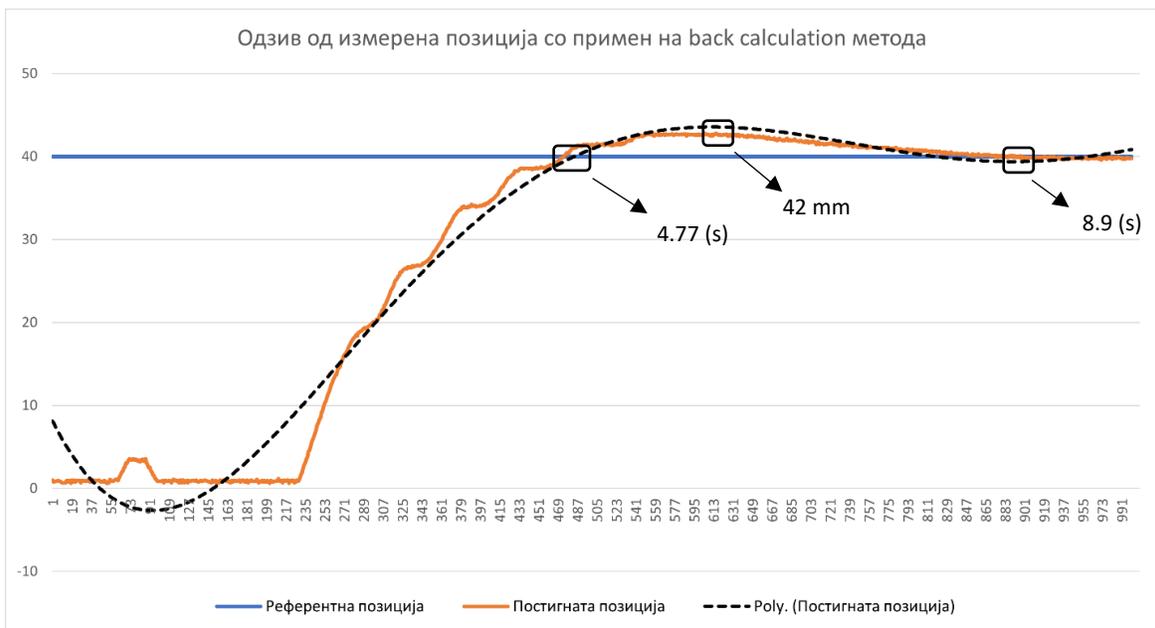


Слика 79. Back-calculation метода за намалување на влијанието на заситувањето за 40 мм и $K_p=690$, $K_i=425$ и $K_d=576$

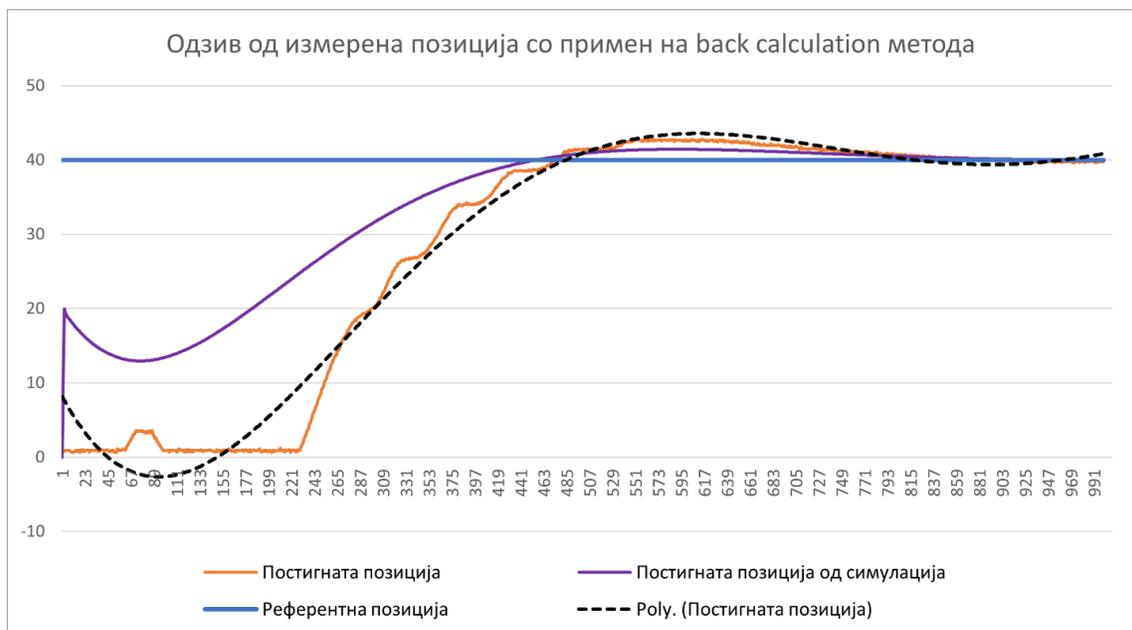
Одзивот прикажан на Слика 79 е типичен одзив којшто се појавува при вметнување на back-calculation anti-windup методата за намалување на влијанието на заситувањето од еден систем, а тоа е забавување на системот при постигнување на референтната вредност, но намалување на прескокот. Доколку се споредат Слика 74 (пик вредноста е 47.7 мм) и Слика 79 (пик вредноста е 41.45 мм), може да се види дека разликата во прескокот при примена на back-calculation anti-windup методата е 14%. Разликата во постигнување на референтантата

вредност е драстично променета и тоа на Слика 75 е за 1.322 секунди, додека на одзивот со применет back-calculation anti-windup е 4.559 секунди.

Со цел верификација на предложената метода, направени се и лабораториски мерења, а резултатите од истите за третата група резултати за $K_p=690$, $K_i=425$ и $K_d=576$ и засилување $K_t = 8.5$ е претставена на Слика 80.



Слика 80. Одзив за постигната позиција 40 мм за трета група резултати ($K_p=690$, $K_i=425$ и $K_d=576$) со примена на back-calculation метода

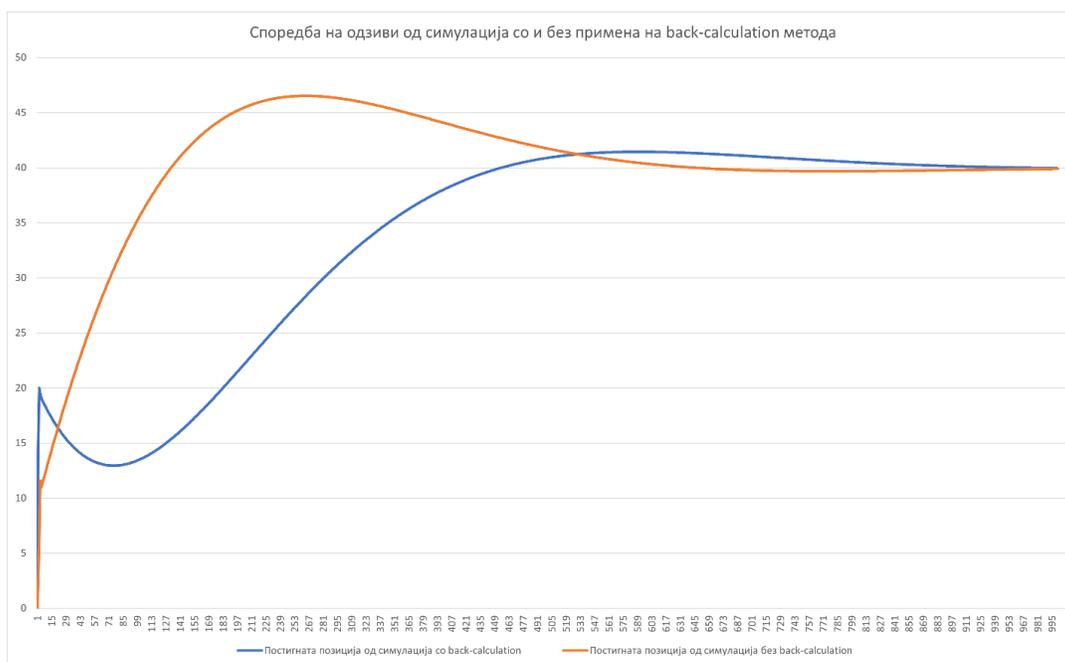


Слика 81. Споредба на одзив од мерење и симулација за постигната позиција 40 мм за трета група резултати ($K_p=690$, $K_i=425$ и $K_d=576$) со примена на back-calculation метода

Разликата којашто се појавува помеѓу симулацискиот модел и извлекувањето измерено со сензор при постигнување на референтна позиција при примена на back-calculation методата е 4.5 %. Во однос на точката на достигнување на стационарна состојба разликата е приближно од 1.2 %.

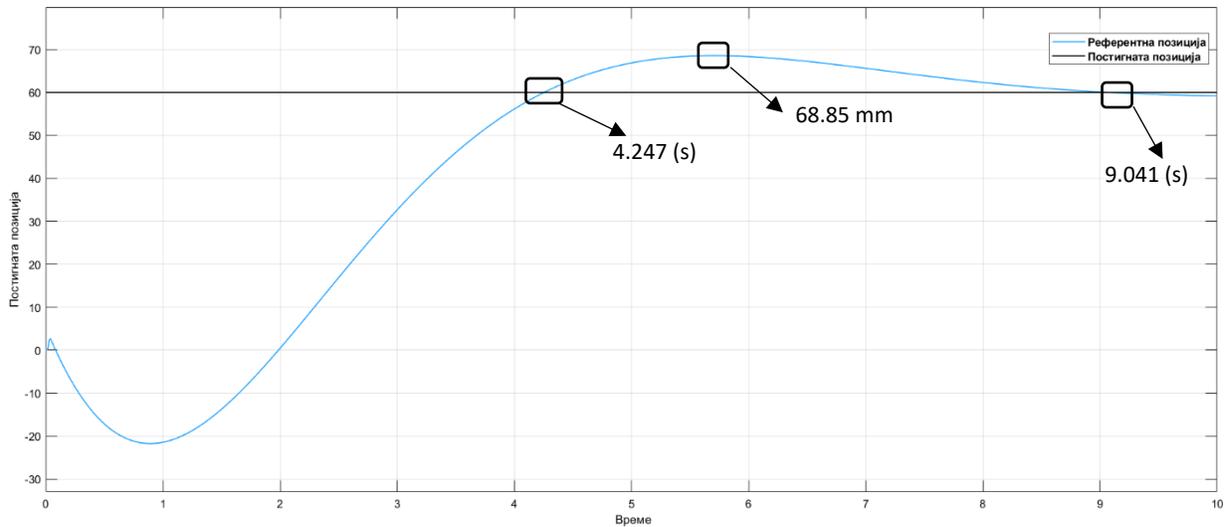
Средната квадратна грешка помеѓу одзивите е 27, додека квадратен корен од средната квадратна грешка е 5.2. Доколку се пресмета средната процентуална грешка помеѓу вистинскиот и одзивот од симулација, се добива 18 % разлика.

На Слика 82 е прикажана споредба на одзивите добиени од симулација со и без примена на back-calculation метода.



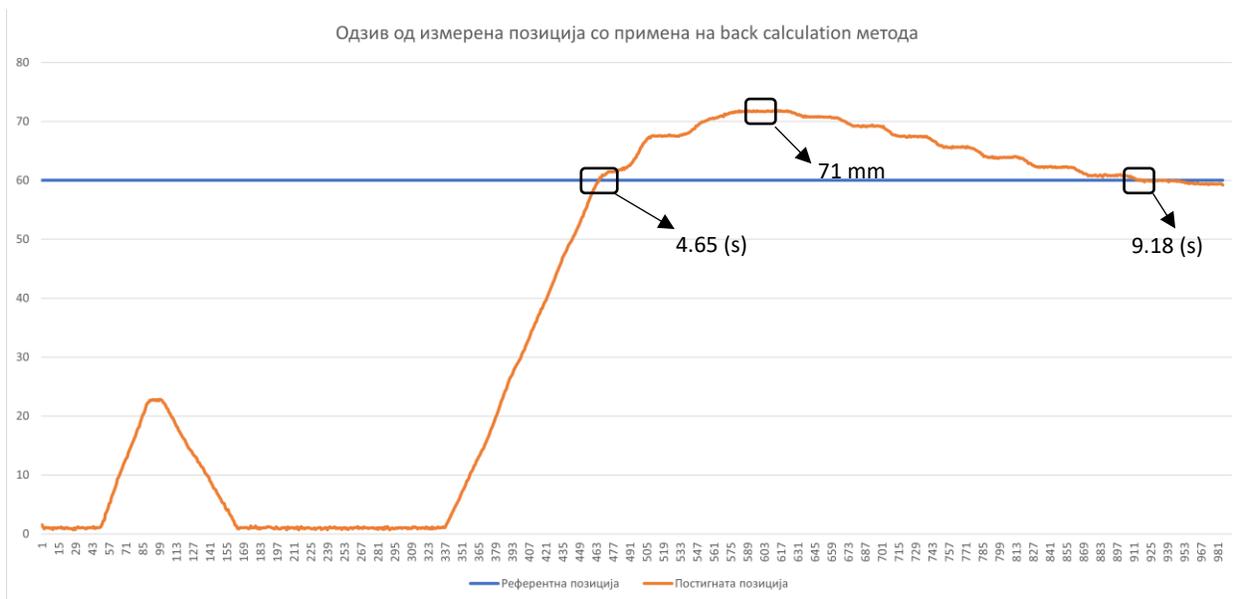
Слика 82. Споредба на одзиви од симулација со и без примена на back-calculation метода

Примената на back-calculation anti-windup методата за **втората група** резултати, $K_p=475$, $K_i=327$ и $K_d=472$ е претставена преку симулациските резултати прикажани на Слика 83. Доколку се споредат со Слика 72, може да се види дека пик вредноста е 74 мм, додека со примена на back-calculation anti-windup методата, пик вредноста е намалена до 68.85 мм. Разликата во пик вредностите е 7.2 %. Разликата во постигнување на референтната вредност е драстично променета и тоа на Слика 72 е за 1.49 секунди, додека на одзивот со применет back-calculation anti-windup, Слика 83 е 4.247 секунди. Таквото доцнење на системот е типичен при примена на оваа метода.



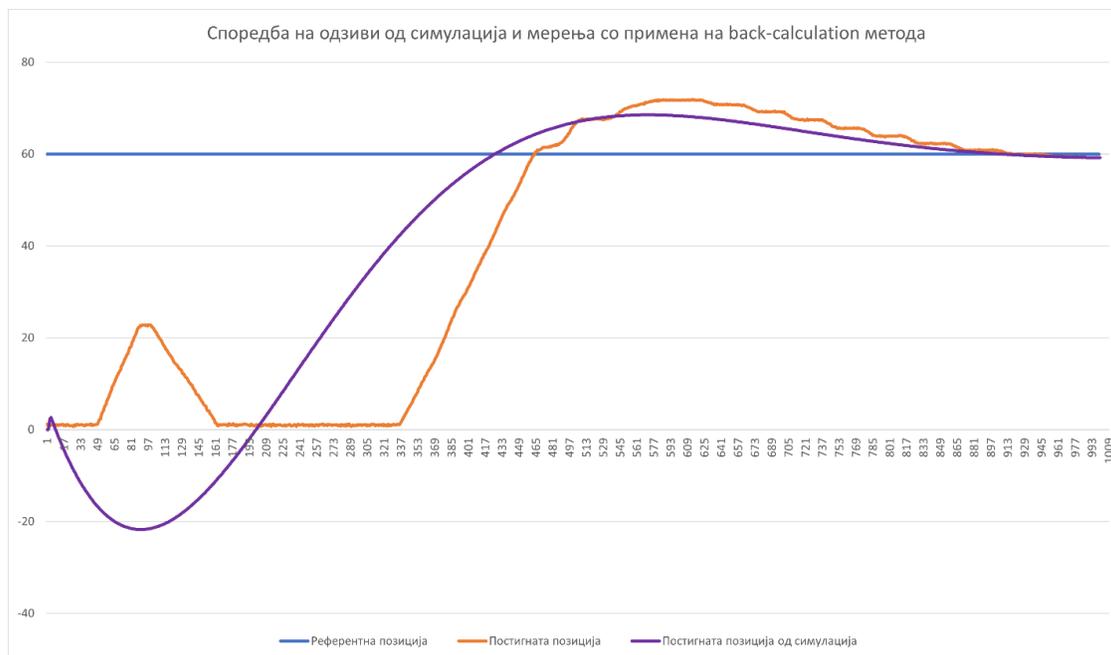
Слика 83. Back-calculation метода за намалување на влијанието на заситувањето за 60 мм и $K_p=475$, $K_i=327$ и $K_d=472$

Со цел верификација на предложената метода, направени се и лабораториски мерења, а резултатите од истите за втората група резултати за $K_p=475$, $K_i=327$ и $K_d=472$ и засилување $K_t = 15$ е претставена на Слика 84.



Слика 84. Одзив за постигната позиција 60 мм за втора група резултати ($K_p=475$, $K_i=327$ и $K_d=472$) со примена на back-calculation метода

На Слика 85 се прикажана споредба на одзивите добиени од симулација и од мерење со цел верификација на добиените константи со примена на ML.

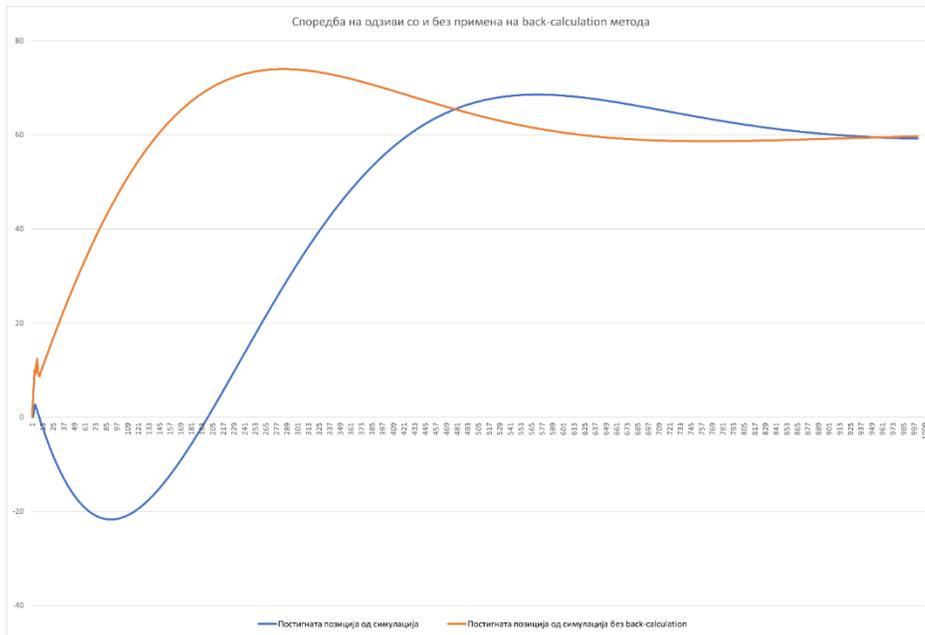


Слика 85. Споредба на одзиви од симулација и мерење со примена на back-calculation метода за поместување 60 мм

Разликата којашто се појавува помеѓу симулацискиот модел и извлекувањето измерено со сензор при постигнување на референтна позиција при примена на back-calculation методата е 9 %. Во однос на точката на достигнување на стационарна состојба, разликата е приближно од 2 %.

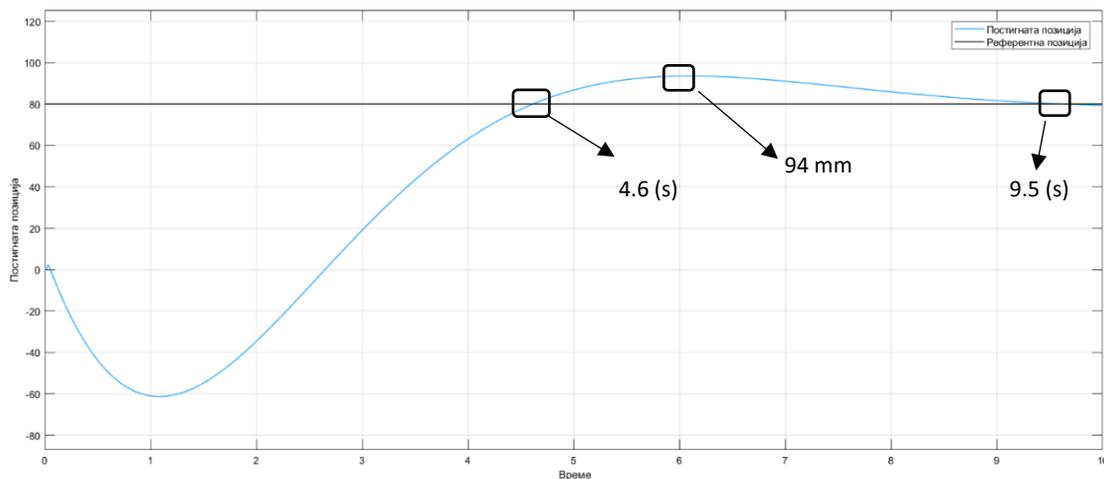
Средната квадратна грешка помеѓу одзивите е 2, додека квадратен корен од средната квадратна грешка е 1,4. Доколку се пресмета средната процентуална грешка помеѓу вистинскиот и одзивот добиен на симулација, се добива 3.4 % разлика.

На Слика 86 е прикажана разликата во одзивите со и без примена на back-calculation anti wind-up методата.



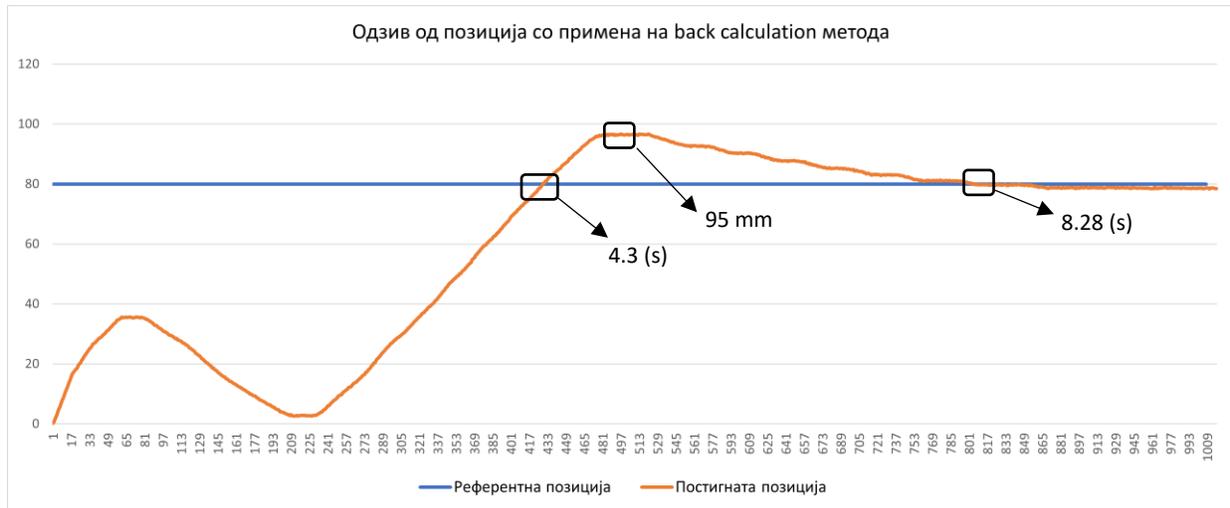
Слика 86. Споредба на одзиви од симулација со и без примена на back-calculation метода за поместување 60 мм

Примената на back-calculation anti-windup методата за **првата група резултати**, $K_p=304$, $K_i=291$ и $K_d=308$ е претставена преку симулациските резултати прикажани на Слика 87. Доколку се споредат со Слика 69 може да се види дека пик вредноста е 102 мм, додека со примена на back-calculation anti-windup методата, пик вредноста е намалена до 94 мм како што е прикажано на Слика 69, согласно резултатите од симулација. Разликата во пик вредностите е 8 %. Разликата во постигнување на референтната вредност е речиси идентична и тоа на Слика 69 е за 1.4 секунди, додека на одзивот со применет back-calculation anti-windup е 4.6 секунди. Таквото доцнење на системот е типично при примена на back-calculation методата.



Слика 87. Back-calculation метода за намалување на влијанието на заситувањето за 80 мм и $K_p=304$, $K_i=291$ и $K_d=308$

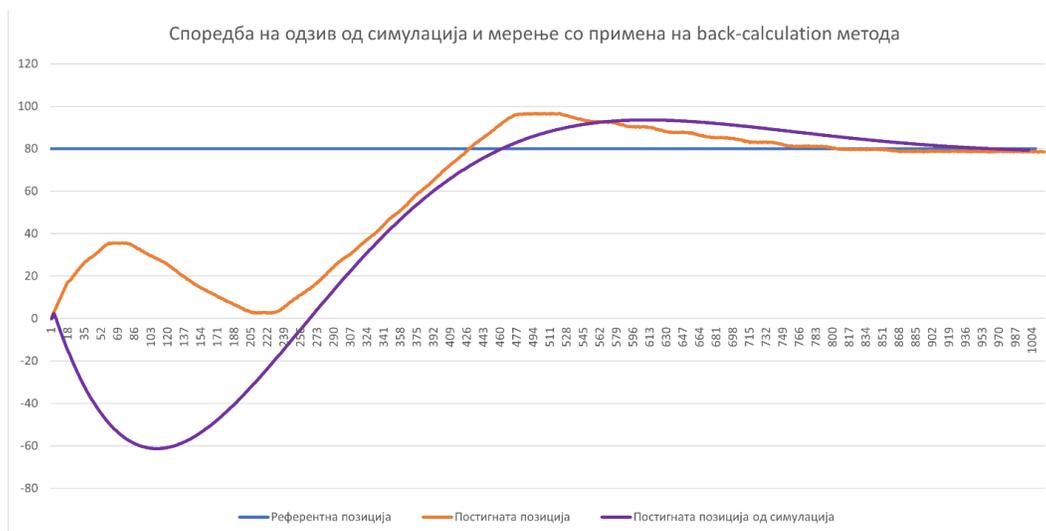
Со цел верификација на предложената метода, направени се и лабораториски мерења, а резултатите од истите за првата група резултати за $K_p=304$, $K_i=291$ и $K_d=308$ и засилување $K_t = 10$ е претставена на Слика 88.



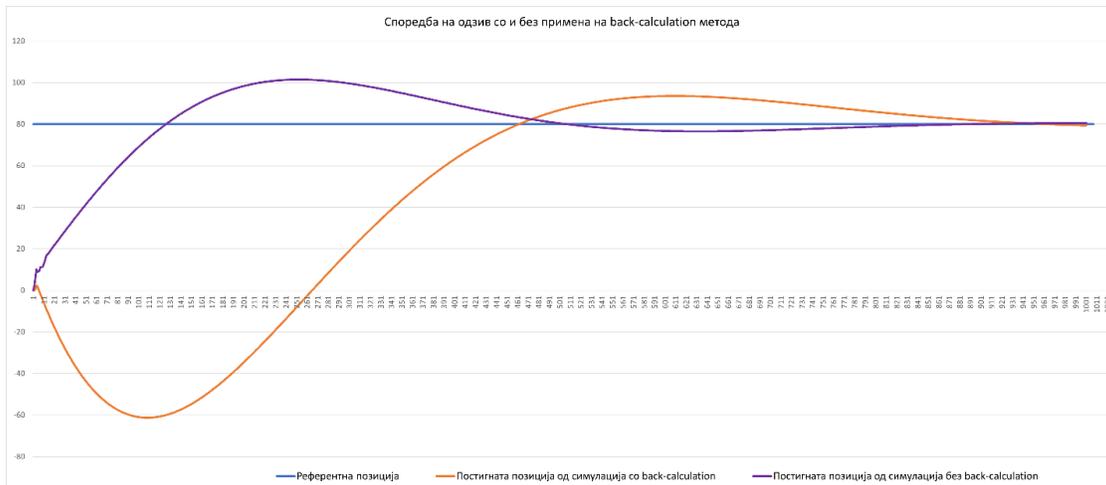
Слика 88. Одзив за постигната позиција 80 мм за втора група резултати ($K_p=304$, $K_i=291$ и $K_d=308$) со примена на back-calculation метода

Разликата којашто се појавува помеѓу симулацискиот модел и извлекувањето измерено со сензор при постигнување на референтна позиција при примена на back-calculation методата е приближно 7 %. Во однос на точката на достигнување на стационарна состојба разликата е приближно од 14 %.

Средната квадратна грешка помеѓу одзивите е 3, додека квадратен корен од средната квадратна грешка е 1.5. Доколку се пресмета средната процентуална грешка помеѓу вистинскиот и одзивот добиен на симулација, се добива приближно 3 % разлика.



Слика 89. Споредба на одзиви од симулација и мерење со примена на back-calculation метода за поместување 80 мм



Слика 90. Споредба на одзиви со и без примена на back-calculation метода за поместување 80 мм

Согласно презентираната метода прикажана на Слика 78 back-calculation, а во однос на тоа и одзивите добиени од симулација, но и со мерења добиени со лабораториска верификација, на Слика 79 до Слика 90 може да се каже дека предложената метода успешно се справува со појавата на проблемот наречен интегрален побег. Потеклото на тој проблем е од примената на ML за предвидување на константите на PID управувањето. Но доколку се анализираат податоците од Табела 12, може да се види дека кај секоја од предвидените парови константи, интегралната константа има многу помала вредност отколку пропорционалната или диференцијалната. Тоа укажува на постоење можност да ML при предвидување на паровите константи, “несвесно” се обидува да го елиминира влијанието на интегралната константа која предизвикува интегрален побег во управувачкиот систем.

6 Глава 6 Заклучок

Примената на вештачката интелигенција (ANN) од ден на ден станува по незапирлива и завзема се поголема примена при обработка на информациите и податоците што се собираат и анализираат со помош на голема процесорска моќ. Помошта која ја нуди ANN е бесконечна доколку ресурсите се користат правилно.

ANN, а со тоа и ML е присутно во речиси секоја област од секојдневниот живот, во медицина, во анализа на економските и банкарски системи, анализа на постројки како што се ветерни централи, термо енергетски постројки, соларни централи. Така и хидроенергетските постројки, согласно досегашниот преглед на литературата во многу мала мера се дел од процесот на анализа и обработка на податоците со примена на ML за нивно подобрување на ефикасноста, динамичките параметри итн. За таа цел во овој докторски труд, ANN и ML се користи за да се анализираат податоците од соодветни параметри превземени од еден хидроенергетски објект како би се овозможило подобрување на динамичките карактеристики, но и подобрување на управувачките можности на разгледуваниот хидроенергетски објект.

На тој начин се додека обработуваниот систем се храни со голем број корисни податоци, работењето на еден хидроенергетски објект може да се направи целосно автономно, секако со дополнителен надзор од страна на оператор поради избегнување на несакани ненадејни настани, настани кои можеби се случуваат по прв пат па ML не е спремен истите да ги детектира, препознае и да алармира за истите. Автономно работење на хидроенергетскиот објект подразбира навремено известување и давање информации корисни и за операторите и за раководителите, но најважно е истата секогаш да биде во исправна состојба и спремна за пуштање во експлоатација.

Прилагодувањето на системот кон автономно работење подразбира употреба на компјутери со огромна процесорска моќ, која ќе може да ги собира, сортира и обработува податоците добиени од сензорите поставени низ целиот хидроенергетски објект. За еден таков систем да може автономно да функционира најпрво е потребно да се воспостави мрежа од сензори кои во текот на една година ќе ги следат сите параметри и настани, а потоа врз основа на истите ќе се прави предвидување на настаните што следуваат.

Доколку има потреба, управувањето на хидрауличната турбина може автоматски да се менува (автоматска промена на параметрите на PID управувањето) во зависност од режимот на работат на истата.

Како во физичката активност така и делумно во интелектуалната способност се почесто се покажува дека човекот може да биде заменет бидејќи тој има ограничен број неврони кои може да обработат ограничен број податоци и информации во одредено време. Колку и да бидат оптоварени тие неврони, одлуките кои би ги донеле се конечни и засновани на претходно стекнати искуства на само една индивидуа, додека вештачката интелигенција може да има бесконечно многу неврони и неуморно да носи одлуки засновани на претходни искуства.

Овој докторски труд е разработен како комбинација од три научни области, примена на ML кај физички системи, управување и создавање дигитален близнак за обработуваните системи. Главна цел и насока на ова истражување е да се осознае влијанието на ML и неговите параметри врз вистински хидроенергетски објекти, дали и како може да се примени управување засновано на NN во хидроенергетски објекти, постројка која што сеуште не е доволно експлоатирана во областа на ML.

Најпрво направена е математичка анализа на управувањето засновано на NN со цел да се види дали тоа е применливо за оваа област, а потоа направено е прилагодување на хидроенергетскиот објект каде што првично управувањето се изведува со примена на PID, кон управување со примена на NN. За да се направи прилагодување, потребно е податочното множество врз основа на кои NN од управувањето ќе се тренира и валидира. За таа цел превземено е податочното множество од реален хидроенергетски објект и врз основа на тие податоци понатаму се користи управување засновано на NN.

Потоа анализирани се повеќето методи на ML, па избрана е методата на супервизорно учење, односно метода која обработува секвенцијални временско-зависни податочни множества, односно рекурентни невронски мрежи (RNN). LSTM и методата на MLP се дел од методите на RNN. Направена е математичка анализа на двете методи посебно со цел да се види математички нивната разлика за потоа да може да се споредат одзивите кои за исто податочното множество даваат различни резултати. Од самата математичка анализа на двете методи согласно добиените резултати, може да се каже дека LSTM методата дава попрецизни резултати кои внесуваат повеќе вистински елементи во моделот.

LSTM и методата на MLP се искористени при идентификација на преносната функција на хидрауличната турбина, но и за одредување на константите на PID управувањето со цел подобрување на динамичките карактеристики на хидроенергетскиот објект.

Исто така овие две методи беа искористени при одредување на временската константа на цевководот T_w . Согласно равенка 2, може да се види дека таа е најважната константа при дефинирање на преносната функција на хидрауличната турбина. Анализирани се повеќе константи што се добиени со примена на ML, а притоа потребно е да се напомене дека за да се добие коефициентот T_w , како влезни и целни излези податочни множества се искористени реални податоци преземени директно од постоечки хидроенергетски објекти.

При разгледување на поголем број техники за управување со системите, може да се каже дека освен PID методата на управување како моментално најкористена и најпопуларна, постојат и други техники за управување и анализа на системите. Методите кои ги вклучуваат ANN, ML, DT или нивна комбинација со било која друга техника како PID, фази или неуро, се со поголемо временско побарување при пресметка на моделот, а за истите потребна е голема процесорска и пресметковна моќност. За наведените техники потребни се големи податочни множества каде што анализираниите процеси историски гледано се повторуваат во континуитет за да може да се направи разлика, да се детектира промена или аномалија, но и да се направи предвидување на процесот којшто се разработува.

Од целокупното истражување и анализа на достапните материјали од областа на управување со хидроенергетски објекти, може да се донесе заклучок дека во овој докторски труд главниот фокус е ставено на примената на ANN, ML, DT и науката за обработка на податоци со цел подобрување на динамичките карактеристики на хидроенергетскиот објект. Освен тоа многу важен дел е создавањето на методологија за проектирање на константите на PID, идентификација на систем, создавање методологија за искористување на податочни множества превземени од SCADA системите на управувачките објекти, но и примена во управувањето со хидроенергетски објекти. Исто така во овој докторски труд главно акцент е ставено на островска работа на хидрауличната турбина со константен број вртежи при црн старт. Техниката од ML која се користи за управување со хидроенергетскиот објект до сега не е пронајден труд кој го разработува и применува со цел добивање подобри динамички карактеристики и подобрување на стабилноста на системот во стационарна состојба. Исто така не е пронајден труд којшто се занимава со дефинирање на методологија за проектирање на константите на PID, идентификација на систем и создавање методологија за искористување на податочни множества превземени од SCADA системи.

Бидејќи постојат повеќе методи на ANN и ML, во овој докторски труд се разгледуваат техниките на MLP и методата на LSTM. Овие две техники се користат бидејќи методата на MLP е далеку поедноставна и бара пократко пресметковно време, но и послаба процесорска моќ, додека LSTM методата е дизајнирана да може да го памти градиентот на функцијата кој исчезнува при секоја итерација доколку се користи било која друга метода од ANN и ML. За таа цел, со LSTM се овозможува подолго задржување на информацијата, но и на самиот градиент пред да се донесе одлука каква информација ќе се појави на излез. Со LSTM се овозможува моделирање и обработка на нелинеарни модели и нивни карактеристики. Поради тоа што е потребен голем број на податочни множества.

Искористени се две сосема различни методи со цел да се направи разлика во добиените резултати, нивната точност, подобрувањето што ќе се добие при нивна примена. Пред се примената на ANN и ML е се повеќе и повеќе популарна метода бидејќи истата нема потреба од математичко моделирање на процесите за кои најчесто е потребно решавање на нелинеарни диференцијални равенки. Едноставно потребно е точна комбинација и збир на точни податоци со соодветна распределба и нивна анализа за создавање на DT.

6.1 Концепт за примена на долга краткорочна меморија техника на управување

Направена е замена на стандардните техники на управување како што е PID управувањето, со примена на ML. Тоа е управувањето засновано на NN или NARMA техника. Примената на ова управување, согласно резултатите од симулација, минимално ги подобрува динамичките карактеристики на еден хидроенергетски објект и кај линеарните и кај нелинеарните модели, само доколку NARMA е искомбинирана со PID управување. Во спротивно само NARMA не може да се справи со нелинеарните карактеристики на системот и постојано се појавува грешка во стационарна состојба. Се претпоставува дека тоа е така поради тоа што NARMA во математичката основа се обидува да го линеаризира моделот откако NN ќе ги обработи податоците и ќе го постигне управувачкиот сигнал. Исто така при

тестирање со симулација, увидено е дека колку системот е подалеку од реалниот модел, толку подобрувањето е поголемо. Колку симулацискиот модел е поблиску до реалната хидропостројка, толку подобрувањето на динамичките карактеристики е помало.

6.2 Споредба на метода на долга краткорочна меморија и метода на повеќеслоен перцептрон

Согласно прикажаните резултати од примена на различни методи на ML, може да се заклучи дека не секогаш и секоја метода применета во било кој случај, ќе даде најдобри резултати. Од многу голема важност е големината и квалитетот на податочното множество, типот на податочното множество, но и изборот на метода за обработка и анализа на податоците. Од тука може да се каже дека не секогаш секоја од методите на ML е соодветна во сите сфери во анализа на податоците. Понекогаш е потребно поедноставен третман на податоците за да може да се извлечат најважните информации бидејќи доколку се оптоварува моделот да обработува податоци кои имаат мала моќ односно се несоодветни тогаш ќе се изгуби квалитетот на резултатите. Во тој случај може да се добие презаситување на моделот при што исто така ќе се добијат несоодветни решенија.

Поради постоењето на различни методи за обработка на податоците, во овој докторски труд се обработуваа, LSTM и MLP методата. Причината за избор на овие две методи е поради тоа што тие обработуваат временско-зависни бази со податоци, но имаат сосема различен математички пристап кон обработка на податочните множества.

Преку примена на симулации, беше увидено дека примената на LSTM методата дава податоци кои пореално го опишуваат системот и ги задоволуваат неговите физички карактеристики, што воедно и беше очекувано поради сложеноста и математичката позадина за обработка на податоците. Во споредба со начинот на пресметка преку MLP, прикажаните резултати се блиску до идеални кои секако се неприменливи во реални услови.

За таа цел при верификација на резултатите добиени од ML, се користи методата на LSTM за пресметување на константи за PID управувањето кои беа применети на експериментална постројка составена од еден хидрауличен цилиндар со двострано дејство и едностран клипница, пумпа и 4/3 пропорционален распоредник. Процентуалната разлика помеѓу измерениот и симулираниот одзив се движи во опсег од 1 до 5 %. Ова покажува дека резултатите добиени од симулација со примена на ML се валидни и применливи.

LSTM и MLP се искористени во овој докторски труд за идентификација на математичкиот модел на хидрауличната турбина. Резултатите од тоа се прикажани во Глава 5. Потребно е да се напомене дека преносната функција на хидрауличната турбина преку методата за идентификација на систем дава најсоодветни резултати кога истата е од прв ред. Се претпоставува дека преносната функција од прв ред добиена од ML дава најзадоволителни резултати бидејќи и вистинскиот линеарен модел на хидрауличната турбина е од прв ред, согласно равенка 2.

6.3 Заклучоци од верификацијата на резултатите добиени со примена на машинско учење

Согласно презентираниите резултати во Глава 5 може да се каже дека комбинацијата на параметрите добиени со примена на ML го прават системот да биде брз, но евидентна е појавата на голем прескок се до стабилна состојба. Тој голем прескок се појавува поради постоењето и влијанието на сатурацијата во системот кој што физички го ограничува сигналот. Таквото ограничување влијае на интегралната компонента од PID управувањето, а тоа пак доведува до појава на голем прескок во одзивот на системот. Тој феномен се нарекува интегрален побег за чие отстранување потребно е да се примени некоја од популарните методи, а тоа е или елиминирање во голема мера на интегралниот член или воведување на back-calculation antiwindup метода. Back-calculation antiwindup методата ги обработува сигналите пред и после сатурацијата. Тој сигнал се засилува со одредена големина и засилениот сигнал се собира со интегралната константа, а потоа се пресметува интеграл на таа вредност. Согласно добиените одзиви може да се види дека примената на оваа метода значително го намалува прескокот во системот, но за таа цел системот станува доста побавен што е типично за применетата метода. Тоа покажува дека ML при предвидување на вредностите се обидува да се справи со појавата на интегрален побег, со самото тоа што се обидува интегралната константа да ја држи ниска, но сепак потребна е дополнителна интервенција за целосно да се намали големиот прескок.

Од тука може да се каже дека ML без примена на човечката интелигенција во некои области кои не се доволно експлоатирани, е неопходно за правилно функционирање и насочување на системот.

6.4 Придонеси од истражувањето

Еден од придонесите од овој докторски труд е дека освен досега познатите техники на управување како што се PID, но и други развиени техники како што е нелинеарно управување или управување со распоред на засилувањата, анализиран е нов пристап кон управувањето со хидроенергетските објекти, односно управување засновано на NN, NARMA. Добиените резултати се анализирани само преку симулација, додека реалното имплементирање на NARMA управувањето е невозможно да се изведе поради потребата од посовремена процесорска моќ која ќе може да ги обработува алгоритмите и оптимизаторите на ML. Но согласно верификацијата направена во Глава 5, може да се каже дека резултатите од симулација и при реално имплементирање ќе се разликуваат од 1 до 5%, а тоа зависи од конфигурацијата на NN и сите хиперпараметри кои се составен и основен дел од ML.

Покажано е дека LSTM и методата на MLP може да се справат со одредена, секвенцијална, временски зависно податочна множество со тоа што кога методата не е соодветна во тој случај директно се добиваат резултати кои отскокнуваат при анализа. Исто така преку овој докторски труд, увидено е влијанието на хиперпараметри и тоа кој параметар како влијае и како го менува одзивот од управувачкиот систем. Согласно истражувањето голема улога игра соодветна и правилна распределба на AF во NN, бидејќи преку неа се прави филтрирање на податоците, со што небитните информации добиваат помало влијание во текот на обработка на податоците, додека податоците со поголемо влијание добиваат поголеми вредности како би имале поголемо влијание во крајниот резултат. Распоредот на AF кои даваат најсоодветни резултати се tanh, sigmoid и relu. По AF, влијание на крајните

резултати има бројот на епохи, па брзината на учење. Комбинацијата на сите овие параметри понатаму зависи и од типот на оптимизатор.

Исто така е увидено дека ML кое влијае врз управувањето на еден систем, се обидува да го направи истиот идеален отстранувајќи ги сите аномалии кое ги обработува во форма на податочни множества. Исфрлањето на сите аномалии го прават системот идеален, нереален за анализа. Кога се обработуваат секвенцијални временско-зависни податочни множества важно е влијанието на секој податок од податочното множество и истиот се филтрира или отстранува само со интервенција на човек кој што добро ја знае физиката на обработуваниот систем.

Преку достапните податочни множества, направен беше дигитален близнак за делови од хидроенергетскиот систем. Направена е методологија за примена на ML при идентификација на управувачките системи и методологија за користење на податочните множества. Поставена е и методологија за проектирање на константите на PID управувањето со примена на ANN и ML.

6.5 Препораки за понатамошно истражување

Во овој докторски труд е извршена анализа на влијанието на делови од ML во процесот на управување и подобрување на динамичките карактеристики на хидропостројка, согласно препораките за понатамошна работа и подобрување на управувањето и динамичките карактеристики наведени во [66].

Со цел да се прошири истражувањето, разработен беше и втор модел на хидропостројка за да се потврди влијанието на NN како дел од ML. Согласно ново развиените техники, препораките за понатамошно истражување на оваа тема би биле:

1. Од аспект на примена на нови и современи техники за анализа на системите, подетално да се обрати внимание на создавањето на модел за дигитален близнак на хидроенергетски објект со цел да може да се симулираат повеќе ефекти и феномени на самиот систем. Тоа би овозможило да се направи детална слика за виртуелна постројка во која ќе се анализираат поголем број на параметри.
2. Од аспект на примена на ML, да се искористат поразлични методи кои би можеле да дадат различни резултати и можеби би можеле дополнително да допринесат за подобрување на динамичките карактеристики на еден хидроенергетски објект. Исто така ML може да се искористи за предвидување на аномалии при работа на хидрауличната турбина или на целиот хидроенергетски објект. За таа цел ќе биде потребно да се направи снимање односно мерење на голем број параметри кои влијаат на споменатите објекти.
3. Од аспект на автоматизирано работење на хидроенергетски објект, да се направи дигитализација на топографскиот дијаграм на хидрауличната турбина со цел полесно да може да се избира работната точка во која најефикасно би можела да работи една хидропостројка во зависност од моменталната побарувачка на електрична енергија, а преку таа автоматизација да можат да се предвидат сите феномени кои би настанале при премин од едно работно подрачје во друго.

4. Да се направи систем за аквизиција на податоци, а истиот да биде инсталиран на хидроенергетскиот објект за континуирано собирање на податоци како би можела да се генерира големо податочно множество за понатамошна обработка со примена на различни методи на ML.
5. Од економски аспект гледано, да се направи пресметка и да се состави буџет за потребната инвестиција и вложување да хидроенергетскиот објект се преориентира и прилагоди за на истиот да може во иднина да се примени вештачка интелигенција за предвидување на настани.

Користена литература

- [1] S. M. Zanolli, C. Pepe, G. Astolfi, and F. Luzi, "Reservoir Advanced Process Control for Hydroelectric Power Production," *Processes*, vol. 11, no. 2, p. 300, Jan. 2023, doi: 10.3390/pr11020300.
- [2] W. Yang, *Hydropower Plants and Power Systems*. Cham: Springer International Publishing, 2019. doi: 10.1007/978-3-030-17242-8.
- [3] O. H. Souza, N. Barbieri, and A. H. M. Santos, "Study of hydraulic transients in hydropower plants through simulation of nonlinear model of penstock and hydraulic turbine model," *IEEE Transactions on Power Systems*, vol. 14, no. 4, pp. 1269–1272, 1999, doi: 10.1109/59.801883.
- [4] Working Group Prime Mover and Energy Supply, "Hydraulic turbine and turbine control models for system dynamic studies," *IEEE Transactions on Power Systems*, vol. 7, no. 1, pp. 167–179, Feb. 1992, doi: 10.1109/59.141700.
- [5] D. Babunski, A. Tuneski, and E. ZaeV, "Simulation of load rejection on a nonlinear Hydro Power Plant model with mixed mode nonlinear controller," in *Mediterranean Conference on Embedded Computing (MECO)*, 2012, pp. 275–278.
- [6] K. P. Bharani Chandra and D. Potnuru, "A nonlinear load frequency controller for hydropower plants," *International Journal of Ambient Energy*, vol. 42, no. 2, pp. 203–210, Jan. 2021, doi: 10.1080/01430750.2018.1531258.
- [7] E. De Jaeger, N. Janssens, B. Malfliet, and F. Van De Meulebroeke, "Hydro turbine model for system dynamic studies," *IEEE Transactions on Power Systems*, vol. 9, no. 4, pp. 1709–1715, 1994, doi: 10.1109/59.331421.
- [8] K. Natarajan, "Robust PID Controller Design for Hydroturbines," *IEEE Transactions on Energy Conversion*, vol. 20, no. 3, pp. 661–667, Sep. 2005, doi: 10.1109/TEC.2005.845448.
- [9] M. R. G. Zoby and J. I. Yanagihara, "Analysis of the primary control system of a hydropower plant in isolated model," *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, vol. 31, no. 1, Mar. 2009, doi: 10.1590/S1678-58782009000100002.
- [10] S. Qu, T. He, and G. Zhu, "Model-Assisted Online Optimization of Gain-Scheduled PID Control Using NSGA-II Iterative Genetic Algorithm," *Applied Sciences*, vol. 13, no. 11, p. 6444, May 2023, doi: 10.3390/app13116444.
- [11] A. A. Zaher, "Design of Model-Based Gain Scheduling Controllers for Nonlinear Systems," *J Phys Conf Ser*, vol. 1141, p. 012117, Dec. 2018, doi: 10.1088/1742-6596/1141/1/012117.
- [12] J. Jiang, "Design of an optimal robust governor for hydraulic turbine generating units," *IEEE Transactions on Energy Conversion*, vol. 10, no. 1, pp. 188–194, Mar. 1995, doi: 10.1109/60.372586.
- [13] O. P. Malik and Y. Zeng, "Design of a robust adaptive controller for a water turbine governing system," *IEEE Transactions on Energy Conversion*, vol. 10, no. 2, pp. 354–359, Jun. 1995, doi: 10.1109/60.391903.

- [14] G. K. Venayagamoorthy and R. G. Harley, "A continually online trained neurocontroller for excitation and turbine control of a turbogenerator," *IEEE Transactions on Energy Conversion*, vol. 16, no. 3, pp. 261–269, Sep. 2001, doi: 10.1109/60.937206.
- [15] R. Kumari, K. K. Prabhakaran, K. Desingu, T. R. Chelliah, and S. V. A. Sarma, "Improved Hydroturbine Control and Future Prospects of Variable Speed Hydropower Plant," *IEEE Trans Ind Appl*, vol. 57, no. 1, pp. 941–952, Jan. 2021, doi: 10.1109/TIA.2020.3028798.
- [16] D. A. Asoh, E. N. Mbinkar, and A. N. Moutlen, "Load Frequency Control of Small Hydropower Plants Using One-Input Fuzzy PI Controller with Linear and Non-Linear Plant Model," *Smart Grid and Renewable Energy*, vol. 13, no. 01, pp. 1–16, 2022, doi: 10.4236/sgre.2022.131001.
- [17] Zhixue Zhang, Zhihong Huo, and Zhihuai Xiao, "PID control with fuzzy compensation for hydroelectric generating unit," in *Proceedings. International Conference on Power System Technology*, IEEE, pp. 2348–2352. doi: 10.1109/ICPST.2002.1047205.
- [18] K. Ramaswamy, "Fuzzy Logic Based Proportional Integral Control of Frequency for Small," *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 9, no. 2, pp. 1275–1279, Apr. 2020, doi: 10.30534/ijatcse/2020/57922020.
- [19] Guang-Da Chen, Wei-You Cai, Han-Ke Xu, and Mian-Hua Huang, "The application of intelligent integral realized by fuzzy logic for hydroturbine governing system," in *Proceedings. International Conference on Machine Learning and Cybernetics*, IEEE, pp. 674–678. doi: 10.1109/ICMLC.2002.1174421.
- [20] M. R. Sathya and M. Mohamed Thameem Ansari, "Load frequency control using Bat inspired algorithm based dual mode gain scheduling of PI controllers for interconnected power system," *International Journal of Electrical Power & Energy Systems*, vol. 64, pp. 365–374, Jan. 2015, doi: 10.1016/j.ijepes.2014.07.042.
- [21] S. Rawat, B. Jha, M. K. Panda, and J. Kanti, "Interval Type-2 Fuzzy Logic Control-Based Frequency Control of Hybrid Power System Using DMGS of PI Controller," *Applied Sciences*, vol. 11, no. 21, p. 10217, Nov. 2021, doi: 10.3390/app112110217.
- [22] S. V. Egoigwe, C. Chukwudozie, C. Nwobi, T. O. Araoye, C. I. Arize, and E. C. Anoliefo, "Application of a Fuzzy Logic Controller for Hydropower Generator Speed Regulation," *European Journal of Engineering Research and Science*, vol. 4, no. 3, pp. 132–135, Mar. 2019, doi: 10.24018/ejers.2019.4.3.1203.
- [23] T. Weldcherkos, A. O. Salau, and A. Ashagrie, "Modeling and design of an automatic generation control for hydropower plants using Neuro-Fuzzy controller," *Energy Reports*, vol. 7, pp. 6626–6637, Nov. 2021, doi: 10.1016/j.egy.2021.09.143.
- [24] X. Gu, Y. Yu, Y. Li, J. Li, M. Askari, and B. Samali, "Experimental study of semi-active magnetorheological elastomer base isolation system using optimal neuro fuzzy logic control," *Mech Syst Signal Process*, vol. 119, pp. 380–398, Mar. 2019, doi: 10.1016/j.ymssp.2018.10.001.

- [25] S. N. V. B. Rao, Y. V. Pavan Kumar, M. Amir, and F. Ahmad, "An Adaptive Neuro-Fuzzy Control Strategy for Improved Power Quality in Multi-Microgrid Clusters," *IEEE Access*, vol. 10, pp. 128007–128021, 2022, doi: 10.1109/ACCESS.2022.3226670.
- [26] K. Uçak and G. Öke Günel, "A Novel Adaptive NARMA-L2 Controller Based on Online Support Vector Regression for Nonlinear Systems," *Neural Process Lett*, vol. 44, no. 3, pp. 857–886, Dec. 2016, doi: 10.1007/s11063-016-9500-7.
- [27] Mustefa Jibril, Messay Tadese, and Eliyas Alemayehu, "Tank Liquid Level Control using NARMA-L2 and MPC Controllers," *ScienceOpen*, May 2020.
- [28] R. Jawad, M. Ahmed, H. Salih, and Y. Mahmood, "Variable Speed Controller of Wind Generation System using Model predictive Control and NARMA Controller," *Iraqi Journal for Electrical and Electronic Engineering*, vol. 18, no. 2, pp. 43–52, Dec. 2022, doi: 10.37917/ijeee.18.2.6.
- [29] T. Mete, G. Ozkan, H. Hapoglu, and M. Alpbaz, "Control of dissolved oxygen concentration using neural network in a batch bioreactor," *Computer Applications in Engineering Education*, vol. 20, no. 4, pp. 619–628, Dec. 2012, doi: 10.1002/cae.20430.
- [30] T. S. Mahmood and O. F. Lutfy, "A Wavelet Neural Network-Based NARMA-L2 Feedforward Controller Using Genetic Algorithms to Control Nonlinear Systems," *Journal Européen des Systèmes Automatisés*, vol. 55, no. 4, pp. 439–447, Aug. 2022, doi: 10.18280/jesa.550402.
- [31] H. Yang, X. Liu, D. Zhang, T. Chen, C. Li, and W. Huang, "Machine learning for power system protection and control," *The Electricity Journal*, vol. 34, no. 1, p. 106881, Jan. 2021, doi: 10.1016/j.tej.2020.106881.
- [32] A. Oluwasegun and J.-C. Jung, "The application of machine learning for the prognostics and health management of control element drive system," *Nuclear Engineering and Technology*, vol. 52, no. 10, pp. 2262–2273, Oct. 2020, doi: 10.1016/j.net.2020.03.028.
- [33] G. Bai *et al.*, "An intelligent water level monitoring method based on SSD algorithm," *Measurement*, vol. 185, p. 110047, Nov. 2021, doi: 10.1016/j.measurement.2021.110047.
- [34] D. Wang *et al.*, "Water plant optimization control system based on machine learning," *Desalination Water Treat*, vol. 222, pp. 168–181, 2021, doi: 10.5004/dwt.2021.27056.
- [35] M.-L. Zhang, Y.-J. Zhang, X.-L. He, and Z.-J. Gao, "Adaptive PID Control and Its Application Based on a Double-Layer BP Neural Network," *Processes*, vol. 9, no. 8, p. 1475, Aug. 2021, doi: 10.3390/pr9081475.
- [36] L. Jasa, A. Priyadi, and M. H. Purnomo, "PID Control for Micro-Hydro Power Plants based on Neural Network," in *Modelling, Identification and Control / 770: Advances in Computer Science and Engineering*, Calgary, AB, Canada: ACTAPRESS, 2012. doi: 10.2316/P.2012.769-039.
- [37] H. N. Hu and W. Wang, "PID Parameters Tuning Based on Wavelet Neural Network for Automatic Voltage Regulator Control System," *Adv Mat Res*, vol. 463–464, pp. 1663–1667, Feb. 2012, doi: 10.4028/www.scientific.net/AMR.463-464.1663.

- [38] B. Krishna, Y. R. S. Rao, and P. C. Nayak, "Time Series Modeling of River Flow Using Wavelet Neural Networks," *J Water Resour Prot*, vol. 03, no. 01, pp. 50–59, 2011, doi: 10.4236/jwarp.2011.31006.
- [39] J. Liu, W. Pan, R. Qu, and M. Xu, "Research on the Application of PID Control with Neural Network and Parameter Adjustment Method of PID Controller," in *Proceedings of the 2018 2nd International Conference on Computer Science and Artificial Intelligence*, New York, NY, USA: ACM, Dec. 2018, pp. 72–76. doi: 10.1145/3297156.3297167.
- [40] J. Chen and T.-C. Huang, "Applying neural networks to on-line updated PID controllers for nonlinear process control," *J Process Control*, vol. 14, no. 2, pp. 211–230, Mar. 2004, doi: 10.1016/S0959-1524(03)00039-8.
- [41] Michael Nikolaou and Vijaykumar Hanagandi, "Control of Nonlinear Dynamical Systems Modelled by Recurrent Neural Networks".
- [42] S. Yahya, A. R. Al Tahtawi, K. Wijayanto, and B. A. Faizah, "Adaptive Fuzzy-PID Controller for Liquid Flow Control in the Heating Tank System," *International Journal of Integrated Engineering*, vol. 14, no. 1, Mar. 2022, doi: 10.30880/ijie.14.01.015.
- [43] R. Bendib and N. Batout, "Boiler Flow Control using Optimal Fuzzy Supervisory PID Controller," in *2018 5th International Conference on Control, Decision and Information Technologies (CoDIT)*, IEEE, Apr. 2018, pp. 370–373. doi: 10.1109/CoDIT.2018.8394865.
- [44] E. B. Priyanka, C. Maheswari, and S. Thangavel, "Online Monitoring and Control of Flow rate in Oil Pipelines Transportation System by using PLC based Fuzzy-PID Controller," *Flow Measurement and Instrumentation*, vol. 62, pp. 144–151, Aug. 2018, doi: 10.1016/j.flowmeasinst.2018.02.010.
- [45] D. A. P. A. Pritandi, "Perancangan Kontroler PID-Fuzzy untuk Sistem Pengaturan Cascade Level dan Flow pada Basic Process Rig 38-100," *Jurnal Teknik ITS*, vol. 5, no. 2, Dec. 2016, doi: 10.12962/j23373539.v5i2.16179.
- [46] A. Rohman, M. A. P. Negara, and B. Supeno, "Sistem Pengaturan Laju Aliran Air pada Plant Water Treatment Skala Rumah Tangga dengan Kontrol Fuzzy-Pid," *BERKALA SAINSTEK*, vol. 5, no. 1, p. 29, Sep. 2017, doi: 10.19184/bst.v5i1.5371.
- [47] S. Sbirna, P. V. Soberg, L. S. Sbirna, and M. Cosulschi, "Sensor programming and concept implementation of a temperature monitoring system, using Arduino as prototyping platform," in *2016 20th International Conference on System Theory, Control and Computing (ICSTCC)*, IEEE, Oct. 2016, pp. 848–853. doi: 10.1109/ICSTCC.2016.7790774.
- [48] V. Pagola, R. Peña, J. Segundo, and A. Ospino, "Rapid Prototyping of a Hybrid PV–Wind Generation System Implemented in a Real-Time Digital Simulation Platform and Arduino," *Electronics (Basel)*, vol. 8, no. 1, p. 102, Jan. 2019, doi: 10.3390/electronics8010102.
- [49] N.-K. Nguyen, "A Novel Improving Technology to Intelligent Controllers – A Typical Case Study for Turbine Speed Regulation of a Smart Hydropower Plant," *International Journal of Emerging Trends in Engineering Research*, vol. 8, no. 6, pp. 2388–2394, Jun. 2020, doi: 10.30534/ijeter/2020/30862020.

- [50] S. P. Giri and S. K. Sinha, "Four-Area Load Frequency Control of an Interconnected Power System Using Neuro-Fuzzy Hybrid Intelligent Proportional and Integral Control Approach," *Journal of Intelligent Systems*, vol. 22, no. 2, pp. 131–153, Jun. 2013, doi: 10.1515/jisys-2012-0025.
- [51] J. Nanda, "Automatic generation control with fuzzy logic controller considering generation rate constraint," in *6th International Conference on Advances in Power System Control, Operation and Management. Proceedings. APSCOM 2003*, IEE, 2003, pp. 770–775. doi: 10.1049/cp:20030683.
- [52] Q. P. Ha, "A fuzzy sliding mode controller for power system load-frequency control," in *1998 Second International Conference. Knowledge-Based Intelligent Electronic Systems. Proceedings KES'98 (Cat. No.98EX111)*, IEEE, pp. 149–154. doi: 10.1109/KES.1998.725839.
- [53] M. Masiala, M. Ghribi, and A. Kaddouri, "An adaptive fuzzy controller gain scheduling for power system load-frequency control," in *2004 IEEE International Conference on Industrial Technology, 2004. IEEE ICIT '04.*, IEEE, pp. 1515–1520. doi: 10.1109/ICIT.2004.1490789.
- [54] Z. Cai *et al.*, "Digital Twin Modeling for Hydropower System Based on Radio Frequency Identification Data Collection," *Electronics (Basel)*, vol. 13, no. 13, p. 2576, Jun. 2024, doi: 10.3390/electronics13132576.
- [55] M. Ersan and E. Irmak, "Development and Integration of a Digital Twin Model for a Real Hydroelectric Power Plant," *Sensors*, vol. 24, no. 13, p. 4174, Jun. 2024, doi: 10.3390/s24134174.
- [56] L. Xiong, J. Liu, B. Song, J. Dang, F. Yang, and H. Lin, "Deep learning compound trend prediction model for hydraulic turbine time series," *International Journal of Low-Carbon Technologies*, vol. 16, no. 3, pp. 725–731, Sep. 2021, doi: 10.1093/ijlct/ctaa106.
- [57] M. A. Bütüner, İ. Koşalay, and D. Gezer, "Machine-Learning-Based Modeling of a Hydraulic Speed Governor for Anomaly Detection in Hydropower Plants," *Energies (Basel)*, vol. 15, no. 21, p. 7974, Oct. 2022, doi: 10.3390/en15217974.
- [58] J. Bernardes *et al.*, "Hydropower Operation Optimization Using Machine Learning: A Systematic Review," *AI*, vol. 3, no. 1, pp. 78–99, Feb. 2022, doi: 10.3390/ai3010006.
- [59] D. J. Wagg, K. Worden, R. J. Barthorpe, and P. Gardner, "Digital Twins: State-of-the-Art and Future Directions for Modeling and Simulation in Engineering Dynamics Applications," *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part B: Mechanical Engineering*, vol. 6, no. 3, Sep. 2020, doi: 10.1115/1.4046739.
- [60] S. A. Varghese, A. Dehlaghi Ghadim, A. Balador, Z. Alimadadi, and P. Papadimitratos, "Digital Twin-based Intrusion Detection for Industrial Control Systems," in *2022 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)*, IEEE, Mar. 2022, pp. 611–617. doi: 10.1109/PerComWorkshops53856.2022.9767492.
- [61] Y. Vered and S. J. Elliott, "The use of digital twins to remotely update feedback controllers for the motion control of nonlinear dynamic systems," *Mech Syst Signal Process*, vol. 185, p. 109770, Feb. 2023, doi: 10.1016/j.ymssp.2022.109770.

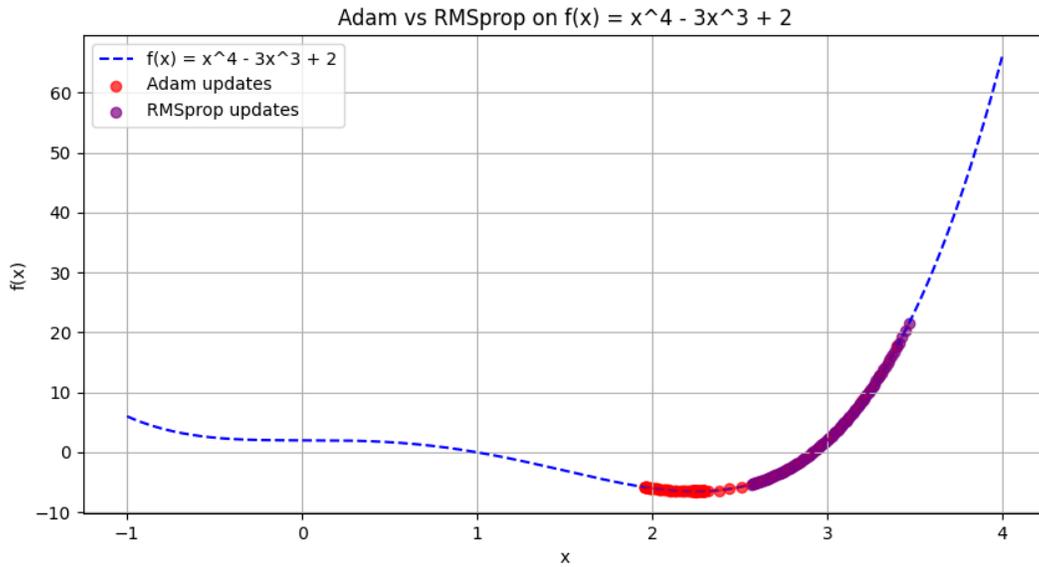
- [62] T. Chen and B.A. Francis, *Optimal sampled-data control systems*. Springer Science & Business Media (2012), 2012.
- [63] K.J. Åström and B. Wittenmark, *Computer-controlled systems: theory and design*. Courier Corporation (2013), 2013.
- [64] *Signal Processing for Active Control*. Elsevier, 2001. doi: 10.1016/B978-0-12-237085-4.X5000-5.
- [65] Дарко Л. Бабунски, “Оптимальни системи за управување со хидроенергетски објекти,” Машински факултет - Скопје, Скопје, 2012.
- [66] Babunski D., “Optimal control systems in hydro power plants Faculty of Mechanical Engineering ,” Ss. “Cyril and Methodius” University, Skopje, 2012.
- [67] Working Group Prime Mover and Energy Supply, “Hydraulic turbine and turbine control models for system dynamic studies,” *IEEE Transactions on Power Systems*, vol. 7, no. 1, pp. 167–179, Feb. 1992, doi: 10.1109/59.141700.
- [68] United Nations Industrial Development Organization (UNIDO), “Hydraulic Machinery and Turbine Generator,” 2019.
- [69] C. Landry, C. Nicolet, J. Gomes, and F. Avellan, *Methodology to determine the parameters of the hydraulic turbine governor for primary control*.
- [70] M. R. G. Zoby and J. I. Yanagihara, “Analysis of the primary control system of a hydropower plant in isolated model,” *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, vol. 31, no. 1, Mar. 2009, doi: 10.1590/S1678-58782009000100002.
- [71] A. Daraz, S. A. Malik, I. U. Haq, K. B. Khan, G. F. Laghari, and F. Zafar, “Modified PID controller for automatic generation control of multi-source interconnected power system using fitness dependent optimizer algorithm,” *PLoS One*, vol. 15, no. 11, p. e0242428, Nov. 2020, doi: 10.1371/journal.pone.0242428.
- [72] Дарко Л. Бабунски, “Оптимальни системи за управување со хидроенергетски објекти,” Машински факултет - Скопје, Скопје, 2012.
- [73] H. Asgari and X. Chen, *Gas Turbines Modeling, Simulation, and Control*. CRC Press, 2015. doi: 10.1201/b18956.
- [74] The MathWorks, “Design Model-Reference Neural Controller in Simulink,” <https://www.mathworks.com/help/deeplearning/ug/design-model-reference-neural-controller-in-simulink.html>. Accessed: Aug. 30, 2022. [Online]. Available: <https://www.mathworks.com/help/deeplearning/ug/design-model-reference-neural-controller-in-simulink.html>
- [75] Jean-Michel Zakoïan and Christian Francq, “Recent Results for Linear Time Series Models with Non Independent Innovations,” in *Statistical Modeling and Analysis for Complex Data Problems* , 2005, pp. 241–265.
- [76] D. B. Percival and A. T. Walden, *Spectral Analysis for Physical Applications*. Cambridge University Press, 1993. doi: 10.1017/CBO9780511622762.

- [77] K. Srakaew, V. Sangveraphunsiri, S. Chantranuwathana, and R. Chanchaen, "Design of NARMA L2 Neurocontroller for Nonlinear Dynamical System," in *Modelling, Identification, and Control*, Calgary, AB, Canada: ACTAPRESS, 2010. doi: 10.2316/P.2010.675-044.
- [78] A. Gundogdu and R. Celikel, "NARMA-L2 controller for stepper motor used in single link manipulator with low-speed-resonance damping," *Engineering Science and Technology, an International Journal*, vol. 24, no. 2, pp. 360–371, Apr. 2021, doi: 10.1016/j.jestch.2020.09.008.
- [79] C. Lv *et al.*, "Levenberg–Marquardt Backpropagation Training of Multilayer Neural Networks for State Estimation of a Safety-Critical Cyber-Physical System," *IEEE Trans Industr Inform*, vol. 14, no. 8, pp. 3436–3446, Aug. 2018, doi: 10.1109/TII.2017.2777460.
- [80] S. Sharma, S. Sharma, and A. Athaiya, "ACTIVATION FUNCTIONS IN NEURAL NETWORKS," *International Journal of Engineering Applied Sciences and Technology*, vol. 04, no. 12, pp. 310–316, May 2020, doi: 10.33564/IJEAST.2020.v04i12.054.
- [81] Sam Roweis, "Levenberg-Marquardt Optimization."
- [82] Henri P. Gavin, "The Levenberg-Marquardt algorithm for nonlinear least squares curve-fitting problems," Nov. 2022.
- [83] Varodom Toochinda, *Feedback Control with Scilab and Arduino*, 1st ed. 2016.
- [84] P. Dev, S. Jain, P. Kumar Arora, and H. Kumar, "Machine learning and its impact on control systems: A review," *Mater Today Proc*, vol. 47, pp. 3744–3749, 2021, doi: 10.1016/j.matpr.2021.02.281.
- [85] Enes Zvornicanin, "Bias Update in Neural Network Backpropagation," <https://www.baeldung.com/cs/deep-learning-bias-backpropagation>.
- [86] C. Nwankpa, W. Ijomah, A. Gachagan, and S. Marshall, "Activation Functions: Comparison of trends in Practice and Research for Deep Learning," Nov. 2018.
- [87] G. E. Dahl, T. N. Sainath, and G. E. Hinton, "Improving deep neural networks for LVCSR using rectified linear units and dropout," in *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, IEEE, May 2013, pp. 8609–8613. doi: 10.1109/ICASSP.2013.6639346.
- [88] M. D. Zeiler *et al.*, "On rectified linear units for speech processing," in *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, IEEE, May 2013, pp. 3517–3521. doi: 10.1109/ICASSP.2013.6638312.
- [89] S. Sharma, S. Sharma, and A. Athaiya, "ACTIVATION FUNCTIONS IN NEURAL NETWORKS," *International Journal of Engineering Applied Sciences and Technology*, vol. 04, no. 12, pp. 310–316, May 2020, doi: 10.33564/IJEAST.2020.v04i12.054.
- [90] W. Hastomo, A. S. Bayangkari Karno, N. Kalbuana, A. Meiriki, and Sutarno, "Characteristic Parameters of Epoch Deep Learning to Predict Covid-19 Data in Indonesia," *J Phys Conf Ser*, vol. 1933, no. 1, p. 012050, Jun. 2021, doi: 10.1088/1742-6596/1933/1/012050.

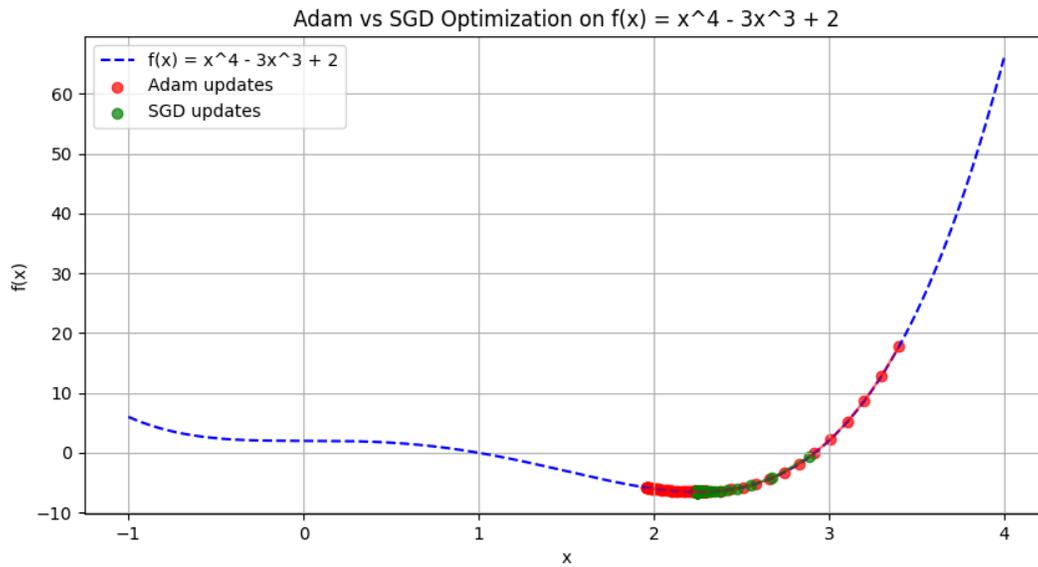
- [91] S. Afaq and S. Rao, "Afaq, S., & Rao, S. (2020). Significance Of Epochs On Training A Neural Network. , 9," *International Journal of Scientific & Technology Research*, vol. 9, no. 06, pp. 485–488, Jun. 2020.
- [92] Chinwe I., Anyama O., Uzoma A. U., and Abasiama S., "Effect of Learning Rate on Artificial Neural Network in Machine Learning," *International Journal of Engineering Research* , vol. 4, no. 2, pp. 359–363, Jun. 2021.
- [93] D. R. Wilson and T. R. Martinez, "The need for small learning rates on large problems," in *IJCNN'01. International Joint Conference on Neural Networks. Proceedings (Cat. No.01CH37222)*, IEEE, pp. 115–119. doi: 10.1109/IJCNN.2001.939002.
- [94] "Intuition of Adam Optimizer." Accessed: Aug. 30, 2022. [Online]. Available: <https://www.geeksforgeeks.org/intuition-of-adam-optimizer/#:~:text=Adam%20optimizer%20involves%20a%20combination,minima%20in%20a%20faster%20pace>
- [95] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," Dec. 2014.
- [96] C. Lv *et al.*, "Levenberg–Marquardt Backpropagation Training of Multilayer Neural Networks for State Estimation of a Safety-Critical Cyber-Physical System," *IEEE Trans Industr Inform*, vol. 14, no. 8, pp. 3436–3446, Aug. 2018, doi: 10.1109/TII.2017.2777460.
- [97] "Intuition of Adam Optimizer." Accessed: Aug. 30, 2022. [Online]. Available: <https://www.geeksforgeeks.org/intuition-of-adam-optimizer/#:~:text=Adam%20optimizer%20involves%20a%20combination,minima%20in%20a%20faster%20pace>
- [98] "Understanding LSTM Networks."
- [99] Andriy Burkov, *THE HUNDRED-PAGE MACHINE LEARNING BOOK*. 2019.
- [100] Debasish Kalita, "A Brief Overview of Recurrent Neural Networks (RNN)," Data Science Blogathon.
- [101] Atul Harsha, "Introduction to Recurrent neural networks and the Math behind them."
- [102] J. Zhang, Y. Zhu, X. Zhang, M. Ye, and J. Yang, "Developing a Long Short-Term Memory (LSTM) based model for predicting water table depth in agricultural areas," *J Hydrol (Amst)*, vol. 561, pp. 918–929, Jun. 2018, doi: 10.1016/j.jhydrol.2018.04.065.
- [103] H. K. Deva Sarma, V. Piuri, and A. K. Pujari, Eds., *Machine Learning in Information and Communication Technology*, vol. 498. Singapore: Springer Nature Singapore, 2023. doi: 10.1007/978-981-19-5090-2.
- [104] Daniel H., "Mathematical Representation of a Perceptron Layer (with example in TensorFlow)."
- [105] M. T. Hagan, H. B. Demuth, and O. De Jesús, "An introduction to the use of neural networks in control systems," *International Journal of Robust and Nonlinear Control*, vol. 12, no. 11, pp. 959–985, Sep. 2002, doi: 10.1002/rnc.727.

- [106] Roger Grosse, "Multilayer Perceptrons," University of Toronto.
- [107] R. Koleva, A. M. Lazarevska, and D. Babunski, "Artificial Neural Network-based Neurocontroller for Hydropower Plant Control," *TEM Journal*, pp. 506–512, May 2022, doi: 10.18421/TEM112-02.
- [108] R. Koleva, D. Babunski, E. ZaeV, F. Poposki, and G. Rath, "Neuro-PID Controller Application for Hydro Power Plant Control," in *2022 11th Mediterranean Conference on Embedded Computing (MECO)*, IEEE, Jun. 2022, pp. 1–4. doi: 10.1109/MECO55406.2022.9797187.
- [109] S. H. Jakobsen, X. Bombois, and K. Uhlen, "Non-intrusive identification of hydro power plants' dynamics using control system measurements," *International Journal of Electrical Power & Energy Systems*, vol. 122, p. 106180, Nov. 2020, doi: 10.1016/j.ijepes.2020.106180.

Додаток



Слика 91. Споредба на брзина на пропагирање кон глобален минимум кај ADAM и RMSprop алгоритам на оптимизација



Слика 92. Споредба на брзина на пропагирање кон глобален минимум кај ADAM и SGD алгоритам на оптимизација

~\OneDrive - Mashinski fakultet - Skopje\Desktop\import numpy as np.py

```

1 import numpy as np
2 import matplotlib.pyplot as plt
3
4 # Function: f(x) = x^4 - 3x^3 + 2
5 def f(x):
6     return x**4 - 3*x**3 + 2
7
8 # Gradient: df/dx = 4x^3 - 9x^2
9 def gradient(x):
10    return 4*x**3 - 9*x**2
11
12 # Hyperparameters
13 alpha_adam = 0.1    # Learning rate for Adam
14 alpha_rms = 0.01   # Learning rate for RMSprop (smaller to prevent instability)
15 beta1 = 0.9        # Momentum term for Adam
16 beta2 = 0.999     # Adaptive term for Adam
17 gamma = 0.9       # Decay rate for RMSprop
18 epsilon = 1e-8    # Small number to prevent division by zero
19
20 # Initial points
21 x_adam = 3.5
22 x_rms = 3.5
23
24 # Adam optimizer variables
25 m, v, t = 0, 0, 0
26
27 # RMSprop optimizer variables
28 v_rms = 0
29
30 # Store updates for visualization
31 adam_path = []
32 rms_path = []
33
34 # Optimization loop
35 epochs = 100
36 for i in range(epochs):
37     t += 1
38     g_adam = gradient(x_adam)
39     g_rms = gradient(x_rms)
40
41     # --- Adam Update ---
42     m = beta1 * m + (1 - beta1) * g_adam
43     v = beta2 * v + (1 - beta2) * (g_adam ** 2)
44     m_hat = m / (1 - beta1 ** t)
45     v_hat = v / (1 - beta2 ** t)
46     x_adam -= (alpha_adam * m_hat) / (np.sqrt(v_hat) + epsilon)
47
48     # --- RMSprop Update ---
49     v_rms = gamma * v_rms + (1 - gamma) * (g_rms ** 2)
50     x_rms -= (alpha_rms * g_rms) / (np.sqrt(v_rms) + epsilon)
51

```

```

2/6/25, 4:42 PM import numpy as np.py
52     # Store progress
53     adam_path.append(x_adam)
54     rms_path.append(x_rms)
55
56 # Visualization
57 x_vals = np.linspace(-1, 4, 1000) # Range for function plot
58 y_vals = f(x_vals)
59
60 plt.figure(figsize=(10, 5))
61
62 # Plot function f(x)
63 plt.plot(x_vals, y_vals, label="f(x) = x^4 - 3x^3 + 2", color="blue", linestyle="dashed")
64
65 # Plot Adam's path
66 plt.scatter(adam_path, [f(x) for x in adam_path], color="red", label="Adam updates",
67             alpha=0.7)
68 plt.plot(adam_path, [f(x) for x in adam_path], color="red", linestyle="solid", alpha=0.6)
69
70 # Plot RMSprop's path
71 plt.scatter(rms_path, [f(x) for x in rms_path], color="purple", label="RMSprop updates",
72             alpha=0.7)
73 plt.plot(rms_path, [f(x) for x in rms_path], color="purple", linestyle="solid", alpha=0.6)
74
75 # Labels and legend
76 plt.xlabel("x")
77 plt.ylabel("f(x)")
78 plt.title("Adam vs RMSprop on f(x) = x^4 - 3x^3 + 2")
79 plt.legend()
80 plt.grid()
81 plt.show()

```

Слика 93. Код со кој се претставува разликата помеѓу ADAM и RMSprop оптимизатор

~\OneDrive - Mashinski fakultet - Skopje\Desktop\ADAM_sdg.py

```

1 import numpy as np
2 import matplotlib.pyplot as plt
3
4 # Function:  $f(x) = x^4 - 3x^3 + 2$ 
5 def f(x):
6     return x**4 - 3*x**3 + 2
7
8 # Gradient:  $df/dx = 4x^3 - 9x^2$ 
9 def gradient(x):
10    return 4*x**3 - 9*x**2
11
12 # Hyperparameters
13 alpha_adam = 0.1 # Adam's learning rate
14 alpha_sgd = 0.01 # SGD's learning rate (smaller to avoid overshooting)
15 beta1 = 0.9 # Adam's momentum term
16 beta2 = 0.999 # Adam's adaptive term
17 epsilon = 1e-8 # Adam's numerical stability constant
18 x_adam = 3.5 # Starting point for Adam
19 x_sgd = 3.5 # Starting point for SGD
20 epochs = 100 # Number of iterations
21
22 # Adam optimizer variables
23 m, v, t = 0, 0, 0
24
25 # Store updates for visualization
26 adam_path = []
27 sgd_path = []
28
29 # Optimization loop
30 for i in range(epochs):
31     t += 1
32     g_adam = gradient(x_adam)
33     g_sgd = gradient(x_sgd)
34
35     # --- Adam Update ---
36     m = beta1 * m + (1 - beta1) * g_adam
37     v = beta2 * v + (1 - beta2) * (g_adam ** 2)
38     m_hat = m / (1 - beta1 ** t)
39     v_hat = v / (1 - beta2 ** t)
40     x_adam -= (alpha_adam * m_hat) / (np.sqrt(v_hat) + epsilon)
41
42     # --- SGD Update ---
43     x_sgd -= alpha_sgd * g_sgd
44
45     # Store progress
46     adam_path.append(x_adam)
47     sgd_path.append(x_sgd)
48
49 # Visualization
50 x_vals = np.linspace(-1, 4, 1000) # Range for function plot
51 y_vals = f(x_vals)

```

2/6/25, 4:41 PM

ADAM_sdg.py

```
52
53 plt.figure(figsize=(10, 5))
54
55 # Plot function f(x)
56 plt.plot(x_vals, y_vals, label="f(x) = x^4 - 3x^3 + 2", color="blue", linestyle="dashed")
57
58 # Plot Adam's path
59 plt.scatter(adam_path, [f(x) for x in adam_path], color="red", label="Adam updates",
60             alpha=0.7)
61 plt.plot(adam_path, [f(x) for x in adam_path], color="red", linestyle="solid", alpha=0.6)
62
63 # Plot SGD's path
64 plt.scatter(sgd_path, [f(x) for x in sgd_path], color="green", label="SGD updates",
65             alpha=0.7)
66 plt.plot(sgd_path, [f(x) for x in sgd_path], color="green", linestyle="solid", alpha=0.6)
67
68 # Labels and legend
69 plt.xlabel("x")
70 plt.ylabel("f(x)")
71 plt.title("Adam vs SGD Optimization on f(x) = x^4 - 3x^3 + 2")
72 plt.legend()
73 plt.grid()
74 plt.show()
75
```

Слика 94. Код со кој се претставува разликата помеѓу ADAM и SGD оптимизатор

Untitled-1

```

1 | # %% [markdown]
2 | # ### Dynamics identification
3 |
4 | # %%
5 | import numpy as np
6 | import os
7 | import pandas as pd
8 | from keras.models import Sequential
9 | from keras.layers import Dense, LSTM
10 | from sklearn.preprocessing import MinMaxScaler
11 | from keras import regularizers
12 | from matplotlib import pyplot
13 | import matplotlib as mpl
14 | import matplotlib.pyplot as plt
15 |
16 | # Load input and output matrices from folder
17 | input_df = pd.read_csv(os.path.join('C:/Users/Radmila/OneDrive - Mashinski fakultet -
18 | Skopje/Desktop/dynamics_implementation', 'Pm_in.csv'))
19 | output_df = pd.read_csv(os.path.join('C:/Users/Radmila/OneDrive - Mashinski fakultet -
20 | Skopje/Desktop/dynamics_implementation', 'Pm_prof.csv'))
21 |
22 | input_matrix = input_df.to_numpy()
23 | output_matrix = output_df.to_numpy()
24 |
25 | # Scale input and output data
26 | scaler = MinMaxScaler(feature_range=(0, 1))
27 | input_matrix_scaled = scaler.fit_transform(input_matrix)
28 | output_matrix_scaled = scaler.fit_transform(output_matrix)
29 |
30 | # Define system transfer function with random zeros and poles
31 | num_zeros = 1 # number of zeros
32 | num_poles = 2 # number of poles
33 |
34 | z = np.random.uniform(low=-1.0, high=1.0, size=num_zeros) # random zero locations
35 | p = np.random.uniform(low=-1.0, high=1.0, size=num_poles) # random pole locations
36 |
37 | # Calculate transfer function coefficients
38 | num_coef = np.poly(z)
39 | den_coef = np.poly(p)
40 |
41 | # Define recurrent neural network architecture
42 | model = Sequential()
43 | model.add(LSTM(258, input_shape=(1, 1), return_sequences=True, activation='tanh',
44 | kernel_regularizer=regularizers.l2(0.01)))
45 | model.add(LSTM(194, activation='tanh', kernel_regularizer=regularizers.l2(0.01)))
46 | model.add(Dense(20, activation='relu', kernel_regularizer=regularizers.l2(0.01)))
47 | model.add(Dense(1))
48 |
49 | # Compile model
50 | model.compile(loss='mean_squared_error', optimizer='adam')
51 |
52 | # Train model

```

```

50 history = model.fit(np.reshape(input_matrix_scaled, (input_matrix.shape[0], 1, 1)),
output_matrix_scaled, epochs=100, batch_size=32, validation_split=0.2, verbose=2)
51
52 # Predict output
53 predicted_output_scaled = model.predict(np.reshape(input_matrix_scaled,
(input_matrix.shape[0], 1, 1)))
54 predicted_output = scaler.inverse_transform(predicted_output_scaled)
55
56 # Evaluate model
57 mse = np.mean((predicted_output - output_matrix) ** 2)
58 print('MSE:', mse)
59
60 # Print system transfer function
61 print('System transfer function numerator coefficients:', num_coef)
62 print('System transfer function denominator coefficients:', den_coef)
63
64
65 # %%
66 from sklearn.datasets import make_regression
67 from sklearn.preprocessing import StandardScaler
68
69 # %%
70 # plot mse during training
71 plt.plot(history.history['loss'])
72 plt.plot(history.history['val_loss'])
73 plt.title('model loss')
74 plt.ylabel('loss')
75 plt.xlabel('epoch')
76 plt.legend(['train', 'val'], loc='upper left')
77 plt.show()
78
79 # %%
80 # Plot transfer function coefficients
81 fig, ax = plt.subplots()
82 ax.plot(num_coef, label='Numerator Coefficients')
83 ax.plot(den_coef, label='Denominator Coefficients')
84 ax.set_xlabel('Coefficient Index')
85 ax.set_ylabel('Coefficient Value')
86 ax.legend()
87 #plt.show()
88
89 # %%
90 import matlab.engine
91 eng = matlab.engine.start_matlab()
92 eng.desktop(nargout=0)
93 model = eng.load_system('C:/Users/Radmila/simulink/proba8.slx')
94
95 # %%
96 eng.set_param('proba8/tfc3', 'Numerator', '[' + str(num_coef[1]) + ']', nargout=0)
97 eng.set_param('proba8/tfc3', 'Denominator', '[' + str(den_coef[1]) + ' ' + str(den_coef[2])
+ ']', nargout=0)
98
99 # %%
100 print(eng.get_param('proba8/tfc3', 'Numerator'))

```

```
101 print(eng.get_param('proba8/tfc3', 'Denominator'))
102
103 # %%
104 # Run simulation
105 eng.set_param('proba8', 'StopTime', '250', nargout=0)
106 eng.set_param('proba8', 'SimulationCommand', 'start', nargout=0)
107 #eng.sim('proba')
108
109 # Extract output signal from simulation results
110 output = eng.workspace['out']
111 omega = eng.getfield(output, 'omega')
112 pm = eng.getfield(output, 'pm')
113 tout = eng.getfield(output, 'tout')
114
115 # %%
116 #print(omega)
117 #rows = [['omega']]
118
119 # Use numpy.savetxt() method to save the list as a CSV file
120 #np.savetxt("omegapm.csv",
121 #           rows,
122 #           delimiter =", ", # Set the delimiter as a comma followed by a space
123 #           fmt = '% s')
124
125 # %%
126 #print(omega)
127
128 # %%
129 plt.plot(tout,omega)
130 plt.plot(tout,pm)
131 plt.show()
132
133 # %%
134 # Close MATLAB engine session
135 #eng.close()
136
137 # %%
138
```

Слика 95. Код за идентификација на систем со примена на LSTM метода за прв реален хидроенергетски објект

Untitled-1

```

1 # %%
2 import numpy as np
3 import pandas as pd
4 import os
5 from keras.models import Sequential
6 from keras.layers import Dense, LSTM
7 from sklearn.preprocessing import MinMaxScaler
8 from keras import regularizers
9 from matplotlib import pyplot
10 import matplotlib as mpl
11 import matplotlib.pyplot as plt
12 from sklearn.neural_network import MLPRegressor
13
14 # Assuming X and Y are NumPy arrays with shape (n_samples, n_features) and (n_samples, 1)
    respectively
15 #n_samples, n_features = X.shape
16 # Load input and output matrices from folder
17
18
19 X = pd.read_csv(os.path.join('C:/Users/Radmila/OneDrive - Mashinski fakultet - Skopje/
    MOC/MFS/Doktorski studii/transfer_function_estimation', 'inputp.csv'))
20 Y = pd.read_csv(os.path.join('C:/Users/Radmila/OneDrive - Mashinski fakultet - Skopje/
    MOC/MFS/Doktorski studii/transfer_function_estimation', 'outputpm.csv'))
21
22 # Define MLP model with 3 hidden layers of 10 neurons each
23 model = MLPRegressor(hidden_layer_sizes=(40, 10, 4), activation='relu', solver='adam',
    max_iter=10000)
24
25 # Train the model on the input and output data
26 model.fit(X, Y)
27
28 # Define system transfer function with random zeros and poles
29 num_zeros = 1 # number of zeros
30 num_poles = 2 # number of poles
31
32 z = np.random.uniform(low=-1.0, high=1.0, size=num_zeros) # random zero locations
33 p = np.random.uniform(low=-1.0, high=1.0, size=num_poles) # random pole locations
34
35 # Calculate transfer function coefficients
36 num_coef = np.poly(z)
37 den_coef = np.poly(p)
38
39 # Extract the learned coefficients
40 weights = model.coefs_
41 biases = model.intercepts_
42
43 # Construct the transfer function from the learned coefficients
44 #num_coef = np.squeeze(weights[0]) # Assuming a single output, so using the weights for the
    first output
45 #den_coef = np.concatenate((np.array([1]), -1 * np.squeeze(weights[-1]),
    np.squeeze(biases[-1])))
46

```

```
47 # Print the transfer function coefficients
48 print("Numerator coefficients:", num_coef)
49 print("Denominator coefficients:", den_coef)
50
51 # %%
52 from sklearn.datasets import make_regression
53 from sklearn.preprocessing import StandardScaler
54
55 # %%
56 import matlab.engine
57 eng = matlab.engine.start_matlab()
58 eng.desktop(nargout=0)
59 model = eng.load_system('C:/Users/Radmila/OneDrive - Mashinski fakultet -
Skopje/Desktop/dynamics_implementation/model_sv_petka/model_svpetka_2.slx')
60
61 # %%
62 eng.set_param('model_svpetka_2/tf2', 'Numerator', '[' + str(num_coef[1]) + ']', nargout=0)
63 eng.set_param('model_svpetka_2/tf2', 'Denominator', '[' + str(den_coef[1]) + ' ' +
str(den_coef[2]) + ']', nargout=0)
64
65 # %%
66 print(eng.get_param('model_svpetka_2/tf2', 'Numerator'))
67 print(eng.get_param('model_svpetka_2/tf2', 'Denominator'))
68
69 # %%
70 # Run simulation
71 eng.set_param('model_svpetka_2', 'StopTime', '250', nargout=0)
72 eng.set_param('model_svpetka_2', 'SimulationCommand', 'start', nargout=0)
73 #eng.sim('proba')
74
75 # Extract output signal from simulation results
76 #output = eng.workspace['out']
77 #omega = eng.getfield(output, 'omega')
78 #pm = eng.getfield(output, 'pm')
79 #tout = eng.getfield(output, 'tout')
80
81 # %%
82 #print(omega)
83
84 # %%
85 plt.plot(tout,omega)
86 plt.plot(tout,pm)
87 plt.show()
88
89 # %%
90 # Close MATLAB engine session
91 #eng.close()
92
93 # %%
94
```

Слика 96. Идентификација на систем со примена на MLP метода за втор реален хидроенергетски објект

Untitled-1

```

1 | # %% [markdown]
2 | # ### Finding Tw
3 | #
4 | # ## sys_ident_tw_1.slx
5 |
6 | # %%
7 | import numpy as np
8 | import os
9 | import pandas as pd
10 | from keras.models import Sequential
11 | from keras.layers import Dense, LSTM
12 | from sklearn.preprocessing import MinMaxScaler
13 | from keras import regularizers
14 | from matplotlib import pyplot
15 | import matplotlib as mpl
16 | import matplotlib.pyplot as plt
17 |
18 | # Load input and output matrices from folder
19 | input_df = pd.read_csv(os.path.join('C:/Users/Radmila/OneDrive - Mashinski fakultet -
20 | Skopje/MØC/MFS/Doktorski studii/transfer_function_estimation', 'inputp.csv'))
21 | output_df = pd.read_csv(os.path.join('C:/Users/Radmila/OneDrive - Mashinski fakultet -
22 | Skopje/MØC/MFS/Doktorski studii/transfer_function_estimation', 'outputpm.csv'))
23 |
24 | input_matrix = input_df.to_numpy()
25 | output_matrix = output_df.to_numpy()
26 |
27 | # Scale input and output data
28 | scaler = MinMaxScaler(feature_range=(0, 1))
29 | input_matrix_scaled = scaler.fit_transform(input_matrix)
30 | output_matrix_scaled = scaler.fit_transform(output_matrix)
31 |
32 | # Define system transfer function with random zeros and poles
33 | num_zeros = 1 # number of zeros
34 | num_poles = 2 # number of poles
35 |
36 | z = np.random.uniform(low=-1.0, high=2.0, size=num_zeros) # random zero locations
37 | #p = np.random.uniform(low=-1.0, high=1.0, size=num_poles) # random pole locations
38 |
39 | # Calculate transfer function coefficients
40 | num_coef = np.poly(z)
41 | #den_coef = np.poly(p)
42 |
43 | # Define recurrent neural network architecture
44 | model = Sequential()
45 | model.add(LSTM(256, input_shape=(1, 1), return_sequences=True, activation='tanh',
46 | kernel_regularizer=regularizers.l2(0.01)))
47 | model.add(LSTM(128, activation='tanh', kernel_regularizer=regularizers.l2(0.01)))
48 | model.add(Dense(3, activation='tanh', kernel_regularizer=regularizers.l2(0.01)))
49 | #model.add(Dense(24, activation='relu', kernel_regularizer=regularizers.l2(0.01)))
50 | model.add(Dense(1))
51 |
52 | # Compile model

```

```

50 model.compile(loss='mean_squared_error', optimizer='adam')
51
52 # Train model
53 history = model.fit(np.reshape(input_matrix_scaled, (input_matrix.shape[0], 1, 1)),
output_matrix_scaled, epochs=100, batch_size=32, validation_split=0.2, verbose=2)
54
55 # Predict output
56 predicted_output_scaled = model.predict(np.reshape(input_matrix_scaled,
(input_matrix.shape[0], 1, 1)))
57 predicted_output = scaler.inverse_transform(predicted_output_scaled)
58
59 # Evaluate model
60 mse = np.mean((predicted_output - output_matrix) ** 2)
61 print('MSE:', mse)
62
63 # Print system transfer function
64 print('System transfer function numerator coefficients:', num_coef)
65 #print('System transfer function denominator coefficients:', den_coef)
66
67
68 # %%
69 from sklearn.datasets import make_regression
70 from sklearn.preprocessing import StandardScaler
71
72 # %%
73 # plot mse during training
74 plt.plot(history.history['loss'])
75 plt.plot(history.history['val_loss'])
76 plt.title('model loss')
77 plt.ylabel('loss')
78 plt.xlabel('epoch')
79 plt.legend(['train', 'val'], loc='upper left')
80 plt.show()
81
82 # %%
83 # Plot transfer function coefficients
84 fig, ax = plt.subplots()
85 ax.plot(num_coef, label='Numerator Coefficients')
86 ax.plot(den_coef, label='Denominator Coefficients')
87 ax.set_xlabel('Coefficient Index')
88 ax.set_ylabel('Coefficient Value')
89 ax.legend()
90 #plt.show()
91
92 # %%
93 import matlab.engine
94 eng = matlab.engine.start_matlab()
95 eng.desktop(nargout=0)
96 model = eng.load_system('C:/Users/Radmila/simulink/proba5.slx')
97
98 # %%
99 eng.set_param('proba5/tfc3', 'Numerator', '[' + str(num_coef[1]) + ']', nargout=0)
100 eng.set_param('proba5/tfc3', 'Denominator', '[' + str(den_coef[1]) + ' ' + str(den_coef[2])
+ ']', nargout=0)

```

```
101
102 # %%
103 print(eng.get_param('proba5/tfc3', 'Numerator'))
104 print(eng.get_param('proba5/tfc3', 'Denominator'))
105
106 # %%
107 # Run simulation
108 eng.set_param('proba5', 'StopTime', '250', nargout=0)
109 eng.set_param('proba5', 'SimulationCommand', 'start', nargout=0)
110 #eng.sim('proba')
111
112 # Extract output signal from simulation results
113 output = eng.workspace['out']
114 omega = eng.getfield(output, 'omega')
115 pm = eng.getfield(output, 'pm')
116 tout = eng.getfield(output, 'tout')
117
118 # %%
119 #print(omega)
120 #rows = [['omega']]
121
122 # Use numpy.savetxt() method to save the list as a CSV file
123 #np.savetxt("omegapm.csv",
124 #           rows,
125 #           delimiter=",", # Set the delimiter as a comma followed by a space
126 #           fmt='% s')
127
128 # %%
129 print(omega)
130
131 # %%
132 plt.plot(tout, omega)
133 plt.plot(tout, pm)
134 plt.show()
135
136 # %%
137 # Close MATLAB engine session
138 eng.close()
139
140 # %%
```

Слика 97. Идентификација на систем за одредување на временска константа на вода во цевководот – Tw

~\PID_prediction_1.ipynb

```

1 import numpy as np
2 import pandas as pd
3 import tensorflow as tf
4 from sklearn.model_selection import train_test_split
5 from sklearn.preprocessing import MinMaxScaler
6 from tensorflow.keras.models import Sequential
7 from tensorflow.keras.layers import Dense
8 from sklearn.model_selection import train_test_split
9
10 # Step 1: Prepare input and output data
11
12 # Load the dataset into a pandas DataFrame
13 data = pd.read_csv('C:/Users/Radmila/OneDrive - Mashinski fakultet -
14 Skopje/Desktop/dynamics_implementation/PID_prediction_3.csv')
15 # Assuming you have numpy arrays 'input_data' and 'output_data' containing your input
16 # features and corresponding Kp, Ki, Kd values
17 # Split the data into input features (wicket gate opening and power) and target variables (Q,
18 # H, and eta)
19 X = data[['PM_in', 'Pm_prof']].values
20 y = data[['kp', 'ki', 'kd']].values
21
22 # Normalize the input features using Min-Max scaling
23 scaler = MinMaxScaler()
24 X = scaler.fit_transform(X)
25
26 # Split the data into training and testing sets
27 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
28
29 # Step 2: Create and train the neural network model
30 model = tf.keras.models.Sequential([
31     tf.keras.layers.Dense(132, activation='sigmoid', input_shape=(X.shape[1],)),
32     tf.keras.layers.Dense(80, activation='tanh'),
33     tf.keras.layers.Dense(3) # Assuming you want to predict Kp, Ki, and Kd values
34 ])
35
36 learning_rate = 0.001 # Specify your desired learning rate
37
38 model.compile(optimizer='adam', loss='mean_squared_error')
39
40 model.fit(X_train, y_train, epochs=100, batch_size=32)
41
42 # Step 3: Perform prediction
43 predictions = model.predict(X_test)
44
45 # Print the predicted Kp, Ki, and Kd values
46 print('Predicted values:', predictions)

```

Слика 98. Код за предвидување на константите на PID управување

Untitled-1

```

1  # %%
2  import pandas as pd
3  import tensorflow as tf
4  from tensorflow import keras
5  from tensorflow.keras.models import Sequential
6  from tensorflow.keras.layers import Activation, Dense
7  from tensorflow.keras.optimizers import Adam
8  from tensorflow.keras.metrics import categorical_crossentropy
9  import os
10 os.environ["PATH"] += os.pathsep + 'C:/Program Files/Graphviz/bin'
11 import numpy as np
12 import pandas as pd
13 import matplotlib as mpl
14 import matplotlib.pyplot as plt
15 from ann_visualizer.visualize import ann_viz;
16 from sklearn.model_selection import train_test_split
17 from tensorflow.keras.layers import Dropout
18 from sklearn.metrics import r2_score
19
20 # %%
21 df = pd.read_csv(r'C:/Users/Radmila/OneDrive - Mashinski fakultet -
Skopje/Desktop/PID_NN/pid_tuning/gain_scheduling_NN/NN_vlez_1.csv')
22
23 # %%
24 df1 = pd.read_csv(r'C:/Users/Radmila/OneDrive - Mashinski fakultet -
Skopje/Desktop/PID_NN/pid_tuning/gain_scheduling_NN/step_2/k.csv')
25 df2 = pd.read_csv(r'C:/Users/Radmila/OneDrive - Mashinski fakultet -
Skopje/Desktop/PID_NN/pid_tuning/gain_scheduling_NN/step_2/k_1.csv')
26 df3 = pd.read_csv(r'C:/Users/Radmila/OneDrive - Mashinski fakultet -
Skopje/Desktop/PID_NN/pid_tuning/gain_scheduling_NN/step_2/k_2.csv')
27 df4 = pd.read_csv(r'C:/Users/Radmila/OneDrive - Mashinski fakultet -
Skopje/Desktop/PID_NN/pid_tuning/gain_scheduling_NN/step_2/k_3.csv')
28 df5 = pd.read_csv(r'C:/Users/Radmila/OneDrive - Mashinski fakultet -
Skopje/Desktop/PID_NN/pid_tuning/gain_scheduling_NN/step_2/k_4.csv')
29 df6 = pd.read_csv(r'C:/Users/Radmila/OneDrive - Mashinski fakultet -
Skopje/Desktop/PID_NN/pid_tuning/gain_scheduling_NN/step_2/k_5.csv')
30 df7 = pd.read_csv(r'C:/Users/Radmila/OneDrive - Mashinski fakultet -
Skopje/Desktop/PID_NN/pid_tuning/gain_scheduling_NN/step_2/k_6.csv')
31 df8 = pd.read_csv(r'C:/Users/Radmila/OneDrive - Mashinski fakultet -
Skopje/Desktop/PID_NN/pid_tuning/gain_scheduling_NN/step_2/k_7.csv')
32 df9 = pd.read_csv(r'C:/Users/Radmila/OneDrive - Mashinski fakultet -
Skopje/Desktop/PID_NN/pid_tuning/gain_scheduling_NN/step_2/k_8.csv')
33 df10 = pd.read_csv(r'C:/Users/Radmila/OneDrive - Mashinski fakultet -
Skopje/Desktop/PID_NN/pid_tuning/gain_scheduling_NN/step_2/k_9.csv')
34
35 # %%
36 #input defined
37 X = df[['x', 'y']]
38 #output defined
39 y= df1[['kp', 'ki', 'kd']]
40 y1= df2[['kp', 'ki', 'kd']]
41 y2= df3[['kp', 'ki', 'kd']]
42 y3= df4[['kp', 'ki', 'kd']]

```

```
43 y4= df5[['kp','ki','kd']]
44 y5= df6[['kp','ki','kd']]
45 y6= df7[['kp','ki','kd']]
46 y7= df8[['kp','ki','kd']]
47 y8= df9[['kp','ki','kd']]
48 y9= df10[['kp','ki','kd']]
49 #print(y)
50
51 # %%
52 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.2, random_state =
42)
53 X_train, X_test, y_train, y_test = train_test_split(X, y1, test_size = 0.2, random_state =
42)
54 X_train, X_test, y_train, y_test = train_test_split(X, y2, test_size = 0.2, random_state =
42)
55 X_train, X_test, y_train, y_test = train_test_split(X, y3, test_size = 0.2, random_state =
42)
56 X_train, X_test, y_train, y_test = train_test_split(X, y4, test_size = 0.2, random_state =
42)
57 X_train, X_test, y_train, y_test = train_test_split(X, y5, test_size = 0.2, random_state =
42)
58 X_train, X_test, y_train, y_test = train_test_split(X, y6, test_size = 0.2, random_state =
42)
59 X_train, X_test, y_train, y_test = train_test_split(X, y7, test_size = 0.2, random_state =
42)
60 X_train, X_test, y_train, y_test = train_test_split(X, y8, test_size = 0.2, random_state =
42)
61 X_train, X_test, y_train, y_test = train_test_split(X, y9, test_size = 0.2, random_state =
42)
62
63 # %%
64 # create ANN model
65 model = Sequential()
66 model.add(Dense(units=156, input_dim=2, activation='sigmoid'))
67 #model.add(Dropout(0.2))
68 #model.add(Dense(15, kernel_initializer='normal',bias_initializer='zeros',
activation='sigmoid'))
69 model.add(Dense(3, activation='linear'))
70 model.summary()
71 #ann_viz(model)
72
73 # %%
74 model.get_weights()
75
76 # %%
77 # Compiling the model
78 model.compile(optimizer=Adam(learning_rate=0.03), loss='mse')
79
80 # %%
81 # Fitting the ANN to the Training set
82 #history=model.fit(X_train, y_train, batch_size = 60, epochs = 50, validation_split=0.1,
shuffle=False, verbose=2)
83 history=model.fit(X, y, batch_size=360, epochs=100, validation_split=0.1, shuffle=True,
verbose=2)
84
```

```
85 # %%
86 history1=model.fit(X, y1, batch_size=360, epochs=100, validation_split=0.1, shuffle=True,
87 verbose=2)
88 # %%
89 history2=model.fit(X, y2, batch_size=360, epochs=100, validation_split=0.1, shuffle=True,
90 verbose=2)
91 # %%
92 history3=model.fit(X, y3, batch_size=360, epochs=100, validation_split=0.1, shuffle=True,
93 verbose=2)
94 # %%
95 history4=model.fit(X, y4, batch_size=360, epochs=100, validation_split=0.1, shuffle=True,
96 verbose=2)
97 # %%
98 history5=model.fit(X, y5, batch_size=360, epochs=100, validation_split=0.1, shuffle=True,
99 verbose=2)
100 # %%
101 history6=model.fit(X, y6, batch_size=360, epochs=100, validation_split=0.1, shuffle=True,
102 verbose=2)
103 # %%
104 history7=model.fit(X, y7, batch_size=360, epochs=100, validation_split=0.1, shuffle=True,
105 verbose=2)
106 # %%
107 history8=model.fit(X, y8, batch_size=360, epochs=100, validation_split=0.1, shuffle=True,
108 verbose=2)
109 # %%
110 history9=model.fit(X, y9, batch_size=360, epochs=100, validation_split=0.1, shuffle=True,
111 verbose=2)
112 # %%
113 # y_train_pred = model.predict(X_train)
114 # y_test_pred = model.predict(X_test)
115
116 # print("The R2 score on the Train set is :\t{:0.3f}".format(r2_score(y_train,
117 y_train_pred)))
118 # print("The R2 score on the Train set is :\t{:0.3f}".format(r2_score(y_test, y_test_pred)))
119 # %%
120 # mlp for regression with mae loss function
121 from sklearn.datasets import make_regression
122 from sklearn.preprocessing import StandardScaler
123 from matplotlib import pyplot
124
125 # %%
126 # plot mse during training
127 plt.plot(history.history['loss'])
128 plt.plot(history.history['val_loss'])
129 plt.title('model loss')
```

```
130 plt.ylabel('loss')
131 plt.xlabel('epoch')
132 plt.legend(['train', 'val'], loc='upper left')
133 plt.show()
134
135 # %%
136 y_pred = model.predict(X_test)
137 plt.plot(y_test, color = 'red', label = 'Real data')
138 plt.plot(y_pred, color = 'blue', label = 'Predicted data')
139 plt.title('Prediction')
140 plt.legend()
141 plt.show()
142
143 # %%
144 # make a single prediction with the model
145 from sklearn.linear_model import LogisticRegression
146 from sklearn.datasets import make_blobs
147 # create the inputs and outputs
148 X, y = make_blobs(n_samples=1500, centers=3, n_features=2, random_state=2)
149 # define model
150 model = LogisticRegression(solver='lbfgs')
151 # fit model
152 model.fit(X, y)
153 # make predictions on the entire training dataset
154 yhat = model.predict(X)
155 # connect predictions with outputs
156 for i in range(1500):
157     print(X[i], yhat[i])
158
159 # %%
160 plt.plot(X, label = 'Predicted data')
161
162 # %%
```

Слика 99. Предвидување на константите на PID при примена на gain scheduling техника на управување