

Факултет инжењерских наука Универзитета у Крагујевцу



Назив студијског програма: Машинско инжењерство

Ниво студија: Мастер академске студије

Модул: Примењена механика и аутоматско управљање

Предмет: Интелигентно управљање

Број индекса: 382/2015

Милош Ђ. Ђорђевић

Идентификација нелинеарних система применом вештачких неуронских мрежа Мастер рад

Комисија за преглед и одбрану:

1. др, Весна Ранковић-ментор

2. _____

3. _____

Датум одбране: _____

Оцена: _____

У оквиру овог мастер рада кандидат треба да идентификује нелинеарни систем другог реда применом вештачких неуронских мрежа. Платформа коришћена за идентификацију је G.U.N.T. Trainer Pressure Control RT532. Састављена је од два резервоара који су међусобно повезани цевима. На улазу система постављен је контролни вентил. Улаз овог система је отвореност управљачког вентила у процентима. Излаз система је притисак у једно од два резервоара нашег избора. Везу између резервоара је могуће мењати вентилима који су уграђени у цевима. Отварање и затварање вентила може променити природу система платформе. Кандидат треба да изврши идентификацију система применом вишеслојног перцептрона и NARX структуре модела. Потребно је извршити оптимизацију добијеног модела.

Препоручена литература:

- [1] Ранковић, В. Интелигентно управљање, Универзитет у Крагујевцу, Машински факултете у Крагујевцу 2008.
- [2] Ковачевић, Б., Квашчев Г., - Идентификација процеса, Универзитет у Београду, Електротехнички факултет 2018.
- [3] Nelles, O., Nonlinear System Identification: From Classical Approaches to Neural Networks and Fuzzy Models, Springer Science & Business Media, 2001.

Крагујевац, јун 2019.

Ментор:
др Весна Ранковић, редовни професор

Резиме:

Процес **идентификације** је један од главних процеса у инжењерству. Као задатак који претходи свакој даљој анализи и синтези система сматра се за уско грло за све даље процесе. Технике идентификације су разноврсне скоро као и сами модели, па тако је потребно изабрати ону која најбоље опонаша систем. Једна од најпопуларнијих метода идентификације је коришћење **вештачких неуронских мрежа**. Неуронске мреже су универзални апроксиматори. Идентификација система на овај начин поседује велики број предности, нарочито у случајевима **нелинеарних** и динамичних процеса. Главни задатак овог рада је да се изврши идентификација система на платформи **G.U.N.T.**.

Кључне речи: идентификација, вештачке неуронске мреже, нелинерни систем, G.U.N.T. Trainer Pressure Control, Matlab.

Abstract:

The process of **identification** is one of the main processes in engineering. As a task that precedes any analysis and synthesis of a system is considered a bottleneck for all latter processes. The techniques of identification are as varied almost as the number of models themselves, therefore there is a need of selecting one that will best mimic the system. One of the most popular methods of identification is the use of **Artificial Neural Networks**. Neural Networks are universal approximators. In this way system identification possesses a great deal of pros, especially in case of **nonlinear** and dynamic processes. The main objective of this thesis is to identify the system of the **G.U.N.T.** platform.

Keywords: Identification, Artificial Neural Networks, Nonlinear Systems, G.U.N.T. Trainer Pressure Control, Matlab

Садржај

1.	УВОД	2
2.	ИДЕНТИФИКАЦИЈА НА ОСНОВУ НЕУРОНСКИХ МРЕЖА	4
2.1	Системи и модели система у идентификацији	4
2.2	Неуронске мреже као модели система	9
2.3	Грешка система и варијансе у оптимизацији модела система	12
2.4	Оптимизација спољашње структуре динамичких модела	15
3.	ПЛАТФОРМА ЗА ИДЕНТИФИКАЦИЈУ	16
3.1	Општи концепт	16
3.2	Контролни вентил	18
3.3	Систем и његови случајеви	22
3.3.1	<i>Случај I</i> – Систем са једним резервоаром	24
3.3.2	<i>Случај II</i> – Систем са два резервоара	24
3.3.3	<i>Случај III</i> – Осцилаторни систем	25
3.4	Кабинет платформе	26
3.5	Софтвер платформе	27
4.	МАТЕРИЈАЛ И МЕТОД	28
4.1	Материјал	28
4.2	Метод	31
4.3	Реализација процеса оптимизације	35
4.4	Примена оптимизације у софтверу	36
5	РЕЗУЛТАТИ И ДИСКУСИЈА	42
6.	ЗАКЉУЧАК	51

ЛИСТА КОРИШЋЕНИХ СКРАЋЕНИЦА:

MLP – Multilayer perceptron

GRANN –General recurrent networks

RANN – Recurrent Neural network

NFIR – Nonlinear finite impulse response

NARX – Nonlinear Autoregressive average with exogenous inputs

NARXMAX –Nonlinear Autoregressive Moving Average with exogenous inputs

ANN -Artificial Neural networks

SCADA – Supervisory Control and Data Acquisition

PLC- Programmable logic controller

1. УВОД

Системи су скупови елемената у међусобном и узајамном деловању на које се могу применити системски закони [1]. Због своје разноврсности они се не могу поделити само на основу једног критеријума. Системи се могу поделити на основу: сложености где разликујемо сложене и једноставне системе, понашања где разликујемо динамичке и статичке системе, одређености понашања где разликујемо детерминистичке и стохастичке итд. Ова подела се базира на понашању система или излазу система док се утицаји који доводе до тог понашања називају улази.

Употреба статистичких метода ради стварања математичког модела система из узоркованих улаза и излаза зове се идентификација система [2]. Сам подухват стварања модела се назива моделирање. Моделирање је поступак добијања математичког описа система који се одвија у реалном свету као што су физички, хемијски или електротехнички процеси, [1]. Показано је у [2-4] да одређени модели боље описују једну врсту система од других. Разлог за такве разлике је структура модела која има ограничену способност да опонаша систем. Дакле, избор модела је кључни фактор процеса моделирања.

Вештачке неуронске мреже (*eng. Artificial Neural Networks*), ANN, су се показале успешне као модели система, што се може видети у [2-14]. ANN припадају огранаци вештачке интелигенције могу да опонашају систем користећи процес учења. Учење се одвија аутоматски на основу изабраног алгоритама [25]. Овај алгоритам мења параметре ANN уз помоћ података улаза и излаза система. Када се покаже да ANN не опонаша систем добро алгоритам учи ANN тако што прилагођава улазе и излазе модела улазима и излазима система. Ако ову операцију поновимо више пута на различитим узорцима улаза и излаза система модел почиње да опонаша систем. Описан подухват називамо идентификацијом система применом ANN. Ради добијања бољих резултата у подучавању могуће је издвојити податке који боље описују систем помоћу еволуционих алгоритмима као у [12].

По [2] недостатак ANN модела је нејасна веза између параметара модела и физичких параметара система који се идентификује. Такође, у [2] закључено је да параметри у ANN сами по себи немају физичко својство из којих би могли да изведемо одређени закључак о физичким карактеристикама система, упркос напорима у раду [15] у коме је пронађена веза између трослојне неуронске мреже и параметара преносне функције система. Упркос таквом недостатку, ANN имају широку примену [3,4]. Добри примери решених проблема применом овог модела су оптимизација у управљању система [6,7], дијагностика грешке система у [8] итд.

У литератури као [2,4] нелинеарни системи се могу идентификовати коришћењем ANN лакше него са осталим методама. Сложеност ових система отежава велики део моделирања зато што правила суперпозиције и хетерогености не важе [2,3]. Користећи ANN олакшавамо идентификацију система јер је процес идентификације аутоматизован. Промена параметара се врши помоћу изабраног алгоритма.

Самоорганизујуће каскадне ANN са насумичним параметрима су имплементирани у идентификацији нелинеарних система [10] и показале се као добро решење. Главна карактеристика у примени ових мрежа на нелинеарне система је њихова способност генерализације. Такође у [11] може се видети комбинација ANN, фази логике, технологије таласића за идентификацију нелинеарних динамичких система. Примери симулације овог хибридног модела су дати у [11] да би се показало повећање тачности у идентификацији нелинеарног система.

У овом раду вршена је идентификација нелинеарног динамичког система другог реда. Уз помоћ специфичних ANN чији су улази регулисани NARX (*eng. Nonlinear Autoregressive average with exogenous inputs*), систем је идентификован. Почетни параметри сваког од коришћеног модел су били насумични. Комбинацијом слојева, броја вештачких неурона у слојевима и регресионог вектора ANN развијени су модели који најбоље описују систем. Параметар који се узима као мера квалитета у идентификацији је највеће одступање од модела. За проверу овако дефинисаног квалитета издвојена је посебна база података. Различите структуре модела су коришћене у раду али издвојене су оне са најбољим квалитетом.

2. ИДЕНТИФИКАЦИЈА НА ОСНОВУ НЕУРОНСКИХ МРЕЖА


Идентификација система претходи синтези контролера у системима аутоматског управљања. Сврха идентификације може бити управљање, оптимизација перформанси система, надгледање система, установљивање грешке или дијагностика система. Резултат овог процеса би био један или више модела- математичког описа који се може поредити са оригиналним системом. Дobar модел једног система омогућава увид у процес реалног система. Када се идентификује систем више нема потребе за реалним системом, сем можда, ако је потребно применити контролер изведен из модела или слично.

2.1 Системи и модели система у идентификацији

Као приказ једног система, P , користи се приказ као на *слици 1* са одређеним бројем утицаја или улаза, u , представљен (2.1) ,

$$u = \{u_1, u_2, \dots, u_p\} \quad (2.1)$$

заједно са одзивом или излазом процеса y .




Слика 1. Графички приказ процеса који има рулаза и један излаз са утицајем поремећаја [9]

Поред наведених улазно-излазних карактеристика једног процеса потребно је приметити поремећај n . Овај елемент представља утицаје који нису под контролом система. Нежељене утицаје је потребно имати у виду када се моделира систем јер утиче на одзив y . Неки модели имају способност уклањања оваквих поремећаја под одговарајућим условима. Таква способност не зависи само од структуре модела већ и од природе поремећаја у систему. Дакле, потребно је поред вредности са којима управљамо додатно имати увид у специфичан случај система кога посматрамо.

Додатно, потребно је навестити природу једног система. Одзив система по понашању могу бити статички –део одзива који је стабилан и конвергира око једне вредности или са друге стране динамички- део одзива код ког протоком времена долази до великих промена. Наравно, сви системи у природи су динамички где неке од промена могу бити корисне а неке штетне. Линеарност једног система је такође битна. Главна карактеристика линеарних система је стриктно важење принципа суперпозиције и хомогености. Такође, линеарни системи зависе само од једног временског интервала као што ни стабилност не сме зависити од почетних услова система. Нелинеарни системи, са друге стране немају овакве квалификације и тешко их је дефинисати.

Моделирање система врши се паралелним постављањем изабраног модела, M , у односу на систем као на *слици 2*. Изложен истим утицајима u као и оригинални систем посматрамо одзив модела, $\hat{y}$. Поређењем реакције модела и процеса добијамо грешку e . Грешку модела је потребно смањити до прихватљивог нивоа. На основу одступања, e , од система модел се мења да би боље опонашао систем који се посматра.

Примећује се да одабрани модел узима и поремећај, n , као део одзива система. На тај начин модел имитира и поремећаје у процесу као део излаза. Ову чињеницу треба имати у виду заједно са свим карактеристикама тог истог поремећаја. Ако дође до промене у поремећају n , модел се може показати као лош.



Слика 2. Генерални приказ процеса моделирања [9]

На *слици 2*, приметно је да је сваки улаз система, P , присутан код модела, M . Међутим ово није нужно приступ који је пожељан у моделирању система. Одређени улази су од већег значаја за процес него други. Додатно, постоји могућност да изабрани модел нема способности да регулише све улазе или да се структурно не подудара са реалним системом. Зависно од случаја, систем може имати више од једног излаза. У том случају појављује се у облику вектора y .

Када се бира модел један од главних фактора који се морају имати у виду је универзалност. Универзалност је способност модела да опише већи број одзива који структурно припадају различитим подсистемима. Степен универзалности зависи од одступања од одзива у систему, као што је то случај и са процесом са једним одзивом.

Дакле, избор улаза модела постаје пресудан корак у идентификацији. Да би изабрали квалитетан модел, потребно је имати увид у сам процес или предзнање о процесу. Како систем постаје сложенији овај избор добија на значају. Увид у разне подсистеме који оперишу унутар система тада постају све важнији. Изоставити само један битан утицај би пресудно пореметио квалитет модела.

У простим системима овај проблем није од велике важности. Обично постоји мали број битних улаза који утичу на систем. По правилу у [9], знатним повећавањем примећује се изједначавање важности сваког од утицаја у процесу. Самим тим модел би показивао много лошије резултате када би сваки улаз био присутан.

Незнање о законима који владају у систему остављају велики јаз у самом процесу моделирања. Коришћењем свих улаза модели могу показати као лоши ако је у питању сложен процес. Изједначавањем сваког утицаја у важности губи се на тачности модела. Ова карактеристика је од важности наручито у случајевима када неки битни улази нису доступни. У таквим случајевима потребно је издвојити само важне сигнале како би надокнадили недостатке проузроковане недоступним улазима.

У недостатку предзнања, један од приступа у овом избору је комбиновање улаза једно са другим. Ова метода се показала као добра код модела са средњим и малим бројем улаза [3]. У случају већег броја ова метода је практично неизводљива [2]. Повећавањем броја улаза знатно повећавамо број различитих модела. Из редова тих модела је потребно пронаћи најбољи избор што је врло тешко и одузима пуно времена [9].

Као пандан поменутој методи, постоји селекција улаза са надгледањем. Овакав приступ се решава преко еволуционих алгоритмима. Могу се развити алгоритми специфични за модел система, који обично раде много ефикасније него комбиновањем свих могућности. За ANN, доступне су бројне технике оптимизације које одбацују неважне параметре или целе неуроне из мреже.

Поред оваквих приступа такође је могуће да се улази бирају без наше селекције или тачније да се бирају без надгледања. Тако постављен приступ дозвољава решавање проблема са пуно комплексних улаза или претерано великим бројем фактора који утичу на модел. Главни пример оваквог приступа је алализа принципијалних компоненти. У овим случајевима најбитнији је критеријум, према коме се рачуна значај улаза.

Поред свих наведених подела система једно од битнијих подела се врши на основу знања о интерној структури система као и о интерним релацијама система [18]. На основу ове поделе системи могу бити беле кутије или системи код кога се зна структура и понашање. Са друге стране, црне кутије су системи о којима немамо знања о структури система и његовом понашању. Између ове две врсте система, усваја се сива кутија код које се само неке релације у структури система не знају.

Поред самог система врло је битно познавати модел који се користи. Скоро сваки модел је предефинисан да има одређене карактеристике а не друге [2]. Мора се приметити да је сваки модел временом стваран како би показао специфичне карактеристике система. Тако, потребно је имати додатно знање о сваком моделу као математичком опису.

Када се бира модел система потребно је имати у виду следеће околности:

- 1) **Тип проблема:** класификација, апроксимација статичких система или идентификација динамичких система.
- 2) **Намена:** жељене карактеристике модела се разликују у зависности од тога да ли ће се модел користити за симулацију, оптимизацију, контролу, откривање грешака итд.
- 3) **Квалитет добијених података:** ако се испостави да су резултати врло лошег квалитета са пуно шума.
- 4) **Време обуке модела:** улази система, количина података и сложеност су битни фактори у брзини обуке модела.
- 5) **Offline или online учење,** тачније обука ван средине у којој ради систем или online обука у средини у коме ће модел радити као решење неког проблема.


Претходно знање о динамици процеса игра битну улогу. Ако је врло мало познато, о динамичности процеса добро решење је модел са интерниом динамиком [16] као што је су рекурентне неуронске мреже (*eng. Recurrent Neuralnetwork*), RNN. То је решење које води ка бољим резултатима јер унутрашње повратне спреге oponaшају динамику система који су тешкеи за анализу. Као додатак овом приступу RNN морају проћи кроз процес стабилизације.

У супротном, приступ спољне динамике са моделом као вишеслојни перцептрон (*eng. Multilayerperceptron*) MLP као у [9] је много бољи избор. Тренутно су предности и мане различитих приказа нелинеарне динамике још увек у процесу истраживања. Дакле, субјективни фактори као што је претходно искуство, са специфичним приступом, играју важну улогу.

Поред система који се идентификује потребно је увидети сложеност модела. Као критеријум једног модела сложеност се дефинише по [9] као број параметара који један модел има. Дакле, сложеност расте повећањем броја параметара и обрнуто. На овај начин повећава се и флексибилност која се дефинише као способност модела да се прилагоди систему. Сложеност, овако дефинисана, не следи нужно флексибилност јер није сваки параметар једнако важан за процес система. Флексибилност је битнија карактеристика када разматрамо моделе у том смислу. Потребно је избегавати модел који је превише једноставан. Тада не би био у стању да идентификује понашање процеса довољно добро. Са друге стране, модел не би требало да буде превише сложен. Дакле, јасно је да негде између мора постојати оптимална сложеност модела.

Наравно, флексибилност и сложеност су у већој мери јасни и лаки концепти када се користе исти или слични модели. Оно што је теже са друге стране је поређење два модела различите врсте. На овом пољу, практично, нема генералне технике за одлучивање која би меродавно могла да води ка једној или другој врсти модела. Увек постоје одређне препоруке из искустава у другим системима. Ако је систем специфичан у неком погледу једини начин утврђивања квалитета модела је да се експериментише са разним моделима. Само на тај начин може се сигурно утврдити успех моделираног система.

Свако напредовање моделирања једног система зависи, у великој мери, од искуства. Тако можемо свести моделирање система на спрегу између предзнања и експериментације са моделом, као на *слици 3, лево*. Наравно, велико предзнање подразумева врло мало додатне експериментације. У том случају потребно је само проучити како се специфичан систем разликује. Разлику је потребно применити на модел и након потврде тачности закључити фазу идентификације. Недостатак предзнања значи додатно експериментисање са улазима и излазима, динамиком, редом, структуром и параметрима модела као на *слици 3, десно*. У [9, 16-19] анализиран је поступак идентификације са ограниченим предзнањима о систему.



Слика 3. лево: Приказ генералног односа предзнања и експериментације у идентификацији, десно: Кораци у идентификацији и формирању модела процеса [9]

2.2 Неуронске мреже као модели система

Вештачке неуронске мреже су осмишљене по узору на неуроне у људском организму, крајем 19. и почетком 20. века када се успостављају прве теорије учења и распознавања [9]. Наравно ове теорије не покривају специфичне алгоритме који данас постоје, већ само идеје. Касније, 1949. године Хеб, (*енг, Hebb*), је предложио први процес учења, као и прва симулација вештачких неуронских мрежа. Розенблат (*енг Rosenblatt*), 1956. године развија прву неуронску мрежу коју је назвао перцептрон која није могла да реши проблеме класификације. Каснијом променом у самој структури неурона и тај систем је успешно решавао проблеме класификације [5].

Повећавањем капацитета рачунара вештачка интелигенција се враћа у употребу. Кроз игре као шах или го ANN се показују као успешне. Са повећањем сложености проблема повећава се и комплексност неуронских мрежа и самим тим облици у коме се појављују ANN.

Како би постојала разлика између ANN од осталих сличних техника идентификације, ANN се описују по критеријуму из [19] на следећим ставкама:

- Велики број простих јединица,
- Добре везе између тих истих јединица,
- Добра робустност против лоших сигнала,
- Паралелне јединице,
- Јединице које је чине имају функције истог типа,
- Могућност да уче из датотека.

Генерално говорећи, овакве мреже нису инспирисане биологијом и структуром самих неурона. ANN имају апстрактну и симболичку везу са биолошким неуронима него копиран биолошки или хемијски систем.

Основна јединица ANN је вештачки неурон (2.2) који се састоји од свог улаза (p_i), излаза (y), појачањима по синапсама, ω_i , и активационе функције, f .


$$y = f \left(\sum_{i=1}^R p_i \omega_i - b \right) \quad (2.2)$$

$$p_i = \{p_1, p_2, p_3, \dots, p_n\} \quad (2.3)$$

$$\omega_i = \{\omega_1, \omega_2, \omega_3, \dots, \omega_n\} \quad (2.4)$$

ANN се формирају од више распоређених, међусобно повезаних неурона (перцептрона) распоређених по слојевима. Спојени у мрежу, повезани су тако да сваки излаз слоја претходних јединица постаје улаз слоја на који се први ослања. Као улазни слој, подрасумевају се сами улази чак и поред чињенице да се не квалификују као неурони. Последњи слој у оваквом низу је окарактерисан као излазни. Све између ова два слоја спада у скривени слој који може наравно по својој карактеристици имати више слојева [18].

По овој дефиницији из [9] можемо поделити вишеслојне мреже у зависности од врсте релација које имају међусобно на нерекурентне и рекурентне. Рекурентне мреже се карактеришу везама који иду у више од једног смера а нерекурентне као мреже које иду само у једном. Ова подела добра је за још додатну карактеризацију унутрашње динамике коју има рекурентна мрежа, ако се везе враћају саме у своје неуроне. Као такве оне су ближе природи, али врло нестабилне имајући у виду повратну спрегу.



Слика 4. Приказ вишеслојне вештачке неуронске мреже [9]

Вишеслојни перцептрон (MLP) се назива универзалним апроксиматором [19]. Тај термин значи да MLP може апроксимирати било коју функцију на одређен степен тачности како се број неурона повећава. Способност универзалне апроксимације је важна особина јер оправдава примену MLP-а на било који проблем апроксимације функције. Разлог зашто је универзална апроксимациона способност MLP-а привукла такву пажњу је тај што се, за разлику од многих других апроксиматора, излаз MLP израчунава комбинацијом једнодимензионалних функција (активацијских функција).

Овај модел може сам себе да тренира. Један од главних начина за тренирање MLP-а је алгоритам пропагације грешке уназад. Промена параметара следи од излазног слоја ка улазу, мењајући вредности синаптичких појачања. Тако би почетно стање параметара било промењено у најоптималније вредности. Такође је потребно редуковати све улазе и сигнале на спектар од $[-3, 3]$, како не би претерано велике вредности улаза доминирале процесом тренирања у неуроима. Разлог за овакав спектар је поменут у [21] у коме се показује да практично било који сигнал ван спектра не остварује битну разлику од крајних вредности тог истог спектра. Наравно, ово правило важи ако се почне од претпоставке да се користе функције као што су сигмоидне и тангентно-сигмоидне.

Једно од технике оптимизације модела MLP заснива се на експлицитној структурној оптимизацији. Она се заснива на промени броја слојева, броја неурона у слоју, променом активационе функције итд. Главни принцип оптимизације MLP је поређење разних комбинација и одабирање оног модела који покаже најбоље резултате. Једно од начина оптимизације модела је напредна селекција.


Напредна селекција је врста оптимизације MLP која почиње од веома једноставног модела, како би у сваком наредном кораку у процесу оптимизације повећавала сложеност модела додавањем параметара или целих подструктура. У многим случајевима, почетни и врло једноставан модел не показује квалитетно идентификован модел. Инкременталним повећавањем неурона у слојевима појачавамо могућност да одређена MLP опонаша лакше систем. Након сваког процеса учења, резултат модела би били поређени са одређени критеријумима који су постављени на почетку процеса идентификације. У случају незадовољавајућег резултата опонашања система следи следећи корак у оптимизацији који додаје још неурона. Оваква операција се понавља све до достизања жељеног резултата. Раст је општи термин за све врсте техника обуке неуронских мрежа које повећавају сложеност мреже додавањем параметара или неурона. Углавном се на вишеслојне перцептронске мреже примењују методе раста. Добро познати приступ је такозвана каскадно-корелацијска мрежа [22].

Елиминација уназад, са друге стране почиње са врло сложеним моделом MLP и уклања параметре неуроне или чак подструктуре у сваком кораку. Оптимизација се завршава тако што се достигне резултат који превазилази границе претходно постављеног критеријума. Пошто овај приступ почиње са веома сложеним моделима, обично је потребно више времена него селекција унапред. Орезивање је општи термин за све врсте техника обуке неуронских мрежа које смањују сложеност MLP уклањањем или параметара или неурона. Као и раст, орезивање се најчешће примењује на вишеслојне перцептронске мреже [23,24].

2.3 Грешка система и варијансе у оптимизацији модела система

Системска грешка је врста грешке која проистиче из реалне неусклађености између реалног процеса и модела који је изабран [9]. Генерално њена вредност је резултат недовољне флексибилности модела да се прилагоди постављен критеријум. У пракси проблеми тачности се често дешавају, јер модели немају способност да одреагују адекватно. Тада, чак и у случају добијемо на почетку најбоље подешене параметре или савршене податке без поремећаја, постоји разлика између процеса и модела. Ако идентификујемо сложен систем, као што је нелинеаран систем, потребно је да се примени један од универзалних апроксиматора као као нпр. MLP, фази системи, итд.

У случају лошег резултата некад је потребно додавати још параметара модела у нади да ће се ова грешка смањити. Логика иза овога је да се у фази мењања параметра битни утицати забележити више и тако повећати тачност на прихватљив ниво. Ако је у питању модел који је нефлексибилан или тачније његова архитектура не дозвољава бољи резултат, повећава се сложеност модела. Овај конкретан приступ процесу оптимизације је описан као раст. Типична реакција код простих модела је да се повећањем броја параметара тачност повећава у великој мери. После одређеног повећања сложености система долази до zasiћености модела где се додавање параметара не одражава великим падом грешке, као што је приказано на *слици 5*.




Слика 5. Однос комплексности система и системске грешке[9]

Још једна мана је у томе што повећавањем броја параметра модела такође усмеравамо модел да буде специфичнији. Овакав модел постаје све мање ефикасан за системе које су до неке мере другачији од конкретног система који посматрамо. Па због овог разлога, потребно је одредити тачну количину параметара ако постоји потреба да се идентификован модел примењује на сличне системе.

Системска грешка, сама по себи, је једноставна за регулацију. Оно што се поставља као главни проблем је грешка варијансе. Овај сегмент грешке карактеришу поремећаји који мењају излаз. Другим речима, прецизност карактерише део система који се заснива у насумичним догађајима независно од модела. Грешка варијансе расте повећањем сигнала поремећаја.

Повећан број параметара повећава способност да на модел утичу одређене вредности улаза преко којих мењамо те исте параметре. Тако, следи да повећавање броја параметра повећава се способност да се и поремећаји опонашају код модела. Мењање параметара на основу поремећаја се показује погубно за квалитет једног модела. Самим тим највећи број параметара отвара прилику за опонашање варијансе грешке и смањује прецизност модела. Ово је генерално правило за било који модел који се користи. На *слици 6* показана је веза између броја параметара и пада прецизности, по једначини (2.9) где је σ варијанса поремећаја, n број параметара, N број узорака за тренирање модела.




Слика 6. Однос варијабилне грешке и комплексности[9]

$$e_v \sim \sigma^2 \frac{n}{N} \quad (2.5)$$

Када погледамо мало боље једначину (2.5), можемо да закључимо да је варијанса поремећаја и број коришћених параметара фиксан или у најбољем случају добро ограничен. Значи, да је најбоља стратегија повећати број узорака система једини параметар тај који би могао смањити ниво грешке варијансе. Тачније, повећањем броја узорака повећавамо и могућност у коме би модел компензовао недостатак лоших података одстранио поремећаје испод одређеног нивоа. Како би се приметио неки облик правилности у процесу.

У сваком реалном процесу ове две грешке се морају комбиновати што нас своди до компромиса у бирању најбољег броја параметара. Превише сложен модел ће дефинитивно проћи лошије сем у случају смањивања броја параметара или повећавањем броја узорака на коме учи модел. Најбоље је наћи оптимално решење. Као пример у коме би имали два пута више узорака у бази података или мање варијансе поремећаја оптимална грешка би била много мања него пре, као на *слици 7*.



Слика 7. Компарација коришћења различитих бројева узорка, позиција лево: А) Мали број коришћених узорака и самим тим већа варијанса грешке, десно: Б) Већи број коришћених узорака и самим тим мања варијанса грешке[9]

2.4 Оптимизација спољашње структуре динамичких модела

Поред унутрашње структуре битну улогу гради и спољашња структура која узима у обзир избор улаза модела који је изабран. Генерално се овај избор своди на регресоре који утичу на модел који имамо. Када је у питању идентификација нелинеарних система по [17], постоје неколико избора регресора- низова сигнала који доприносе оптимизацији модела као:

1) NFIR – Нелинеарни модел са коначним импулсним одзивом, чији се одзив карактерише једначином (2.2)

$$\hat{y} = (k|k - 1, \theta) = F(\varphi(k), \theta) \quad (2.2)$$

$$\varphi(k) = \{u(k - 1), u(k - 2), u(k - 3), \dots, u(k - n_b)\} \quad (2.3)$$

у коме је (2.3) регресиони вектор, а F нелинеарна функција, θ вектор параметара у коме је k тренутни временски интервал који је потребно предвидети, b број улаза који се користи у регресионом вектору.

2) NARX – Нелинеарни ауто-регресиони модел са спољашњим улазом, чији је регресиони одзив такође карактерише једначине (2.2) са променом регресионог вектора приказаног (2.4)

$$\varphi(k) = \{u(k - 1), u(k - 2), u(k - 3), \dots, u(k - n_b), \\ y(k - 1), y(k - 2), y(k - 3), \dots, y(k - n_a)\} \quad (2.4)$$

где је a , број регресионих вредности процеса кога изучавамо.

3) NARXMAX – Нелинеарни ауто-регресиони модел помичних средина са спољашњом побудом чији је одзив такође у облику (2.2) а регресиони вектор (2.5)

$$\varphi(k) = \{u(k - 1), u(k - 2), u(k - 3), \dots, u(k - n_b), \\ y(k - 1), y(k - 2), y(k - 3), \dots, y(k - n_a), \\ e(k - 2|k - 3, \theta), e(k - 3|k - 4, \theta), \dots, e(k - n_c|k - n_c - 1, \theta)\} \quad (2.5)$$

где је c , број грешке модела које враћамо моделу ради боље оптимизације.

Нелинеарна функција Φ може да се апроксимира помоћу MLP.

3. ПЛАТФОРМА ЗА ИДЕНТИФИКАЦИЈУ

3.1 Општи концепт

G.U.N.T. Trainer Pressure Control RT532 је експериментална платформа која управља компресованим ваздухом који испуњава један/два резервоара. Као свака пнеуматска платформа која управља одређеним вредностима потребан је контролни вентил и систем у који се ваздух убризгава под притиском. У овој платформи могуће је променити карактеристике система што додатно компликује идентификацију потенцијалним случајевима у оквиру саме платформе. У току одзива једног система узоркују се све битне вредности управљања као што је показано у [25]. Цела платформа ограничена металном конструкцијом.

Као додатан регулатор у спрези овог процеса укључује се и програмабилни логички контролер (PLC), софтвер RT620, као додатни начин управљања са личног рачунара. RT620 је програмиран на основу SCADA софтвера. Поред поменутих, у [25] постоји и опција снимања управљачких вредности директно на папир. Постоји и дигитално снимање уз помоћ серијске везе која повезује персонални рачунар и микроконтролер. Праћене вредности такође могу бити изражене аналогним сигналом уз помоћ мерних инструмената за јачину струје.




Слика 8. Реални приказ система *G.U.N.T. TrainerPressureControlRT532* као пример идентификације [26]

Систем приказан, као главни улаз, добија ваздух под притиском од стране компресора од 8 bar (бара). Гас улази у филтер или регулаторну јединицу која дели ток ваздуха на два канала: од 6 bar и 2 bar. Они служе као улаз система и управљачки сигнал актуатора, респективно. Проток ваздуха система се усмерава вентилом ка једном од два резервоара. Усмерење ваздуха зависи од два вентила који се ручно отварају и затварају. Ако могућа стања вентила подразумевамо као тотално отворене и тотално затворенем по предлогу [25], платформа потенцијално може имати укупно три случаја система.

Поред регулаторних вентила, могуће је отворити издувни вентил уграђен на други резервоар. Овако, потенцијално се може симулирати поремећај у сигналу. Као додатни поремећај могуће је отворити вентиле на сваком од резервоара, *слика 9, позиција 1 и 3*. Ради сигурности сваки резервоар има сигурносни вентил у случају превезилажења критичног притиска у резервоарима. Ови притисци се могу видети на манометрима, *слика 9, позиција 7*.

Поред описаног система постоји два начина мерења притиска код ове платформе: мерење притисака горњег или доњег капацитета. Као мерни инструмент користи се трансдуктор, *слика 9, позиција 2*. Притисак одређене коморе се мери у барима и претвара у аналогни електрични сигнал. Такав сигнал се везује на PLC. Одабиром одређеног контролера преко повратне спреге заједно са претходним улазом следи коригован сигнал управљачком вентилу који повећава или смањује притисак по потреби.




Слика 9. Склоп модула система *G.U.N.T. Trainer Pressure Control RT532*, позиција: 1) доњи капацитет-резервоар, 2) трансдуктор који контролише мерење, 3) горњи капацитет- резервоар, 4) дигитални контролер притиска, 5) штампач за забележење притисака, 6) електрични кабинет 7) манометар, 8) пнеумацки контролни вентил[26]

3.2 Контролни вентил

Као кључни елемент овог система, мора се издвојити контролни вентил. Сваки контролни вентил је састављен из актуатора и вентила. Функционисање контролног вентила заснива се на отварању и затварању вентила уз помоћ актуатора. Вентили могу бити различите врсте у зависности од начина отпуштања протока у том истом вентилу. Могу се поделити на вентиле са диском, затварачем, дијафрагмом итд. Када је у питању изабрани вентил платформе, он функционише на основу затварача. Овај вентил контролише ваздух под притиском уз помоћ актуатора. Највећи могући притисак који вентил може да пропусти је 6 bar.

Актуатори пнеуматског типа могу контролисати процес преко цилиндра, дијафрагме и опруге. Они зависе од типа вентила који се користи у самом процесу. Начин функционисања пнеуматских актуатора генерално се заснива на убризгавању ваздуха у једну или две коморе актуатора у којој, преко притиска, помера мембрану повезану са механизмом који је повезан са вентилом. У зависности од начина убризгавања притиска ови актуатори се могу поделити на једноструко активне и двоструко активне.




Слика 10. лево: Скица нормално затвореног контролног вентила у отвореном положају, десно: Скица нормално затвореног контролног вентила у затвореном положају, позиције 1) Уплив сигнала управљања, 2) смер у коме се опруге померају ради отварања, 3) Вентил који контролише прилив, 4) Улаз притиска, 5) Излаз притиска, 6) Опруге актуатора, 7) Затварач, 8) Контролна комора актуатора, [27]

Једноструко активан принцип функционисања механизма се заснива на упливу притиска у једну комору која би притискала другу комору у одређеном интезитету. Секундарна комора овај притисак трпи и пружа отпор неким механичким елементом (обично је овај елемент опруга одређених квалитета). Када се отпор друге коморе уравнотежи са притиском прве коморе добијамо жељену вредност отворености вентила.

Код двоструко активних актуатора, отвореност вентила се регулише тако што обе коморе имају сопствен прилив притиска. У зависности од потребне позиције, актуатор доводи притисак у једну комору а смањује је у другој. У тренутку када позиција затварача вентила долази на жељену позицију притисци у коморама се изједначавају.

Ваздух који улази у комору актуатора је управљачки сигнал из пнеуматског регулатора. По [28] најчешће коришћени управљачки сигнал у облику ваздушног притиска је у спектру од 0,2 до 1 bar. Потребно је обратити додатну пажњу на нормално затворен актуатор (који се користи у овом случају) са стандардним опругама од 0,2 до 1,0 bar, постављеним у комори која директно управља процесом померања дијафрагме. Када се вентил и актуатор калибришу, они се подешавају тако да притисак ваздуха од 0,2 bar тек почне да превазилази отпор опруга и помера затварач вентила из седишта. Како се притисак ваздуха повећава, затварач вентила се постепено помера више, док коначно вентил при притиску од 1 bar не отвори 100%.


Нека је овај актуатор инсталиран у једном систем где је његов задатак смањење притиска у систему са 10 на 4 bar. Диференцијални притисак вентила је у том случају разлика између два стања или тачније 6 bar. Овај притисак делује на доњу страну затварача вентила, обезбеђујући силу отпора која тежи отварању вентила, супротно намерама. Поменути отпор се додаје сили која потиче од притиска ваздуха у актуатору, и самим тим ремети управљачки сигнал у погрешном смеру. Према [28], ако се актуатор снабдева ваздухом од 0,6 бара, на пола пута између 0,2 и 1 бар би, на пример, уместо да вентила заузима очекивани 50% отворени положај, стварни отвор ће бити већи, због додатног отпора диференцијалног притиска. Такође, ова додатна сила значи да вентил није затворен на 0,2 бара, у свом намереном 100% затвореном положају. Да би се затворио вентил у овом примеру, контролни сигнал се мора смањити приближно на 0,1 bar, што регулатор нема могућности да примени подразумевајући силу опруге од 0,2 bar у стању минималног управљачког сигнала. Као на *слици 11*.



Слика 11 лево: Приказ утицаја диференцијалног сигнала на перформансе актуатора при затвореном стању, десно: приказ актуатора у тотално затвореном стању, позиције;

1) Начелна вредност потреног управног сигнала, 2) Резултанта вредности управног сигнала под утицајем диференцијалног притиска, 3) Разлика између два сигнала, 4) Уплив управљачког сигнала, 5) Смер у коме се опруге притискају, 6) Улаз притиска, 7) Излаз притиска [27]

Као помоћ у поменутој ситуацији, додатно на актуатор се може уградити позиционар који ће од управљачког сигнала регулисати кретање вретена које затвара/отвара вентил. Главна његова функција је надокнађивање притиска до позиције вентила који захтева управљачки сигнал.




Слика 12. Нацрт позиционара на актуатору и његови улази, позиције: 1) Управљачки сигнал, 2) Доток ваздуха под притиском, 3) Излаз позиционара у управљачку комору, 4) Позиционар, 5) Стубови актуатора[27]

У поменутим случајевима сам притисак није довољан да превазиђе отпор који се налази у другој комори. Ти проблеми могу бити трење у актуатору, притисак у вентилу итд. Ово је главни проблем који се решава овим позиционаром. У нашем случају улазни сигнал који долази од контролера је електрични и самим тим потрено га је претворити у притисак који додатно утиче на актуатор. Овај притисак добијамо уз одвојен ток од 2 bar који се регулише из филтера притиска на почетку улаза притиска од 8 bar. Повратна спрега која потврђује потез се регулише тако што се посматра вретено које се спушта и подиже. Позиционар је фиксиран за два стуба актуатора и повезан са вретеном преко којег добијамо повратну информацију која би пратила позицију контролног вентила. Могуће је користити као додатну помоћ јаче опруге, али је практичнији приступ помоћу позиционара. Овај додатак прослеђује улазни сигнал и позицију контролног вентила и предаје било који излаз који ће дозволити тражени положај.

Треба напоменути да је позиционер, по својој природи, пропорционално појачање, и тако следи и очекивање да ће овакав пропорционални регулатор, што је позиционар у суштини увек дати помак само као такав. На типичном позиционару, по [28], пропорционална грешка може бити у спектру између 3 и 6%. Осетљивост позиционера се обично може подесити, као одговор на овај проблем. За прецизно управљање потребно је минимизирање оваквих недостатака.

Пракса је таква да за притиске у спектру до 3 bar користи управљачки притисак од 0,2 до 1 bar, док је за веће притиске до 13 bar се укључује позиционар са појачањем на управљачки сигнал на спектар од 1 до 2 bar, као на *слици 13*. Модел коришћен у експерименту је Samson 3277, као и на *слици 14*.



Слика 13. Ефекат појачања пнеуматског актуатора преко позиционара,
 Позиције: 1) Управни сигнал без појачања 2) Управни сигнал са појачањем,
 3) Притисак затворене позиције доступан са појачањем, 4) Притисак затворене позиције доступан без појачања, 5) Излаз позиционара, 6) Управљачки сигнал, 7) Прилив ваздуха под притиском[7]



Слика 14. Приказ актуатора коришћеног на платформи G.U.N.T. TrainerPressureControlRT532

Пример коришћен у експерименту се базира на једноструко активном дијафрагмалним актуатором са затварачким вентилом. Дуга притисна комора актуатора поседује у себи две опруге које регулишу отпор притиска. Заједно са позиционаром овај контролни вентил чини кључни инструмент управљања у платформи за идентификацију и управљање.

3.3 Систем и његови случајеви

Као опште место за ове системе које је дато у [26], узима се да су системи другог реда. Као такав, подређен је нелинеарним динамичким карактеристикама у првом циклусу свог одвијања, што значи зависност од прошлих или чак и будућих вредности у свом математичком облику. Оваква природа платформе за експериментацију је врло проблематична не само за идентификацију већ и за управљање или симулацију, где је идентификација само први корак.


Његова друга фаза је фаза мировања која је статичка по својим карактеристикама. Такви системи су врло лаки за идентификацију јер захтевају једноставне математичке моделе који су успешни до одређених граница зависно од решења за његову идентификацију. Задати програм, преко кога се управљасистемом, заснива се на подешавању одскочне вредности до које желимо доћи подењавајући PID. Када актуатор добије вредност из контролера затварач се позиционира у зависности од управљачке вредности. Главно ограничење овог система је константан притисак од 6 bar. Врло је могуће да у неком тренутку одређени контролни сигнал тражи додатни притисак из контролног вентила да би га надокнадио. Самим тим, систем није савршен и функцијонише између горњег и доњег спектра притисака од 1-2 bar.

Када је реч о систему, могуће је додавати и одузимати елементе, *слика 15*, који ће мењати природу тог система, претварајући сваки случај у одвојени систем сам за себе. Ова могућност се заснива на вентилима који могу усмерити компресовани ваздух у једно од два резервоара. Додатно могуће је отворити вентил који има могућност спајања система. Први елемент који дефинише систем је вентил за усмеравање који може бити усмерен ка једном од два резервоара. Други вентил служи за прекид или стварање везе између поменутих капацитета. Трећи и коначни елемент је трансдуктор који бира резервоар по коме ће се систем карактерисати. Као такав, игра велику улогу, јер диктира природу система и начин његовог карактерисања. Генералне комбинације свих ових елемената су постављене у *табели 1* по препоруци [25].

Табела 1. Подела врсте подешавања система по препоруци [25]

Вентил за усмерење	на горњи капацитет	на горњи капацитет	на доњи капацитет
преливни Вентил	Затворен	отворен	отворен
Вентил трансдуктора	на горњи капацитет	на горњи капацитет	на доњи капацитет


Као додатак, уграђен је испусни вентил, *слика 15, позиција 6*, који служи за генерисање поремећаја. Он може имати вредности од полу отвореног до цео отворен по коме се регулише интензитет поремећаја [25]. Генерално постоје три опције под почетном претпоставком да сви вентили могу бити тотално отворени или затворени и то су: систем са једним резервоаром, систем са два резервоара и осцилаторни систем.



Слика 15. Скица система за идентификацију, позиција: 1) Контролни вентил 2) Вентил за усмерење притиска 3) Преливни вентил 4) Вентил трансдуктор 5) Манометри 6) отпусни вентил 7) Резервоари 8) Трансдуктор, 9) Сигурносни вентил, 10) Прилив ваздуха [26]

3.3.1 Случај I – Систем са једним резервоаром


Први случај је тај у коме је вентил за усмеравање подешен ка другом- горњем резервоару. Са затвореним другим вентилом који пропушта притисак у први - доњи резервоар. Компресовани ваздух наставља ка другом и једином преосталом резервоару са полу отвореним отпусним вентилом. Проток ваздуха у систему је приказан на *слици 16, лево*. Свака комбинација у систему је предложена у [25]. Одзив оваквог система приказан је на *слици 16, десно*.



Слика 16.лево: Приказ првог случаја, десно: одзив првог система [26]

3.3.2 Случај II– Систем са два резервоара


Разлика овог случаја од претходног је потпуно отворен други вентил. Ваздух наставља да тече кроз цев која се у вентилу дели на оба резервоара. На овај начин притисак испуњава оба резервоара. Зато што је доњи исте величине као горњи, резервоар систем тако добија дупли капацитет. Овако постављени систем се дефинише као паралелно везан. Проток ваздуха у систему је приказан на *слици 17, лево*. Одзив овог система је приказан на *слици 17, десно*, на којој можемо приметити разлику у управљачком сигналу, *слика 17, десно, црна линија*.



Слика 17.лево: Приказ другог случаја, десно: одзив другог система [26]

3.3.3 Случај III- Осцилаторни систем

Последњи систем се разликује у томе што је први усмерни вентил подешен ка првом резервоару. Тако промењен у односу на други случај редно је везан за други резервоар. Додатна промена је та у којој је трансдуктор усмерен ка првом резервоару. Ово подешавање пуни доњи резервоар прво и из отвора прослеђује горњем. Конфигурација је другачија од осталих, јер у том случају постоји први поремећај који се одликује у одливу ка горњем капацитету. Даљим пуњењем горњег резервоара, ваздух под притиском се ослобађа преко одпусног вентила и то све за време пуњења доњег капацитета, *слика 18, лево*. Усмерењем трансдуктора на доњу посуду следи да овако конфигурисан систем изражава карактеристике осцилаторног система или система који као своје стање равнотеже има криву са одређеном фреквенцијом. У нашем случају одзив овог система приказан је на *слици 18, десно*.



Слика 18.лево: Приказ трећ случаја, десно: одзив трећегсистема [26]

3.4 Кабинет платформе

Место у коме се сабирају сва информације служи као спрега између контролног вентила и система је електрични кабинет који нуди разне опције. Првобитно овај кабинет мери притисак преко трансдуктора, који може мерити од 0 до 6 bar у облику електричног сигнала од 4 до 20 mA. Тако се наставља на PLC који регулише стање у систему и подешава параметре PID контролера. На овај начин регулисан електрични аналогни сигнал се шаље на позиционар који претвара електрични сигнал у притисак.

Додатно постоји опција праћења стања притиска и затворености вентила преко излаза на кутији у облику електричног сигнала такође: затвореност вентила у облику напона а притисак као и у облику трансдуктора у облику јачине струје од 4 до 20 mA. Ове две вредности диктирају целу природу овог система па и зато се могу такође мерити са континуалним сниматељем који је постављен на горењем левом углу. Овим избором могуће је имати у писаном облику кретање стања главних криви.




Слика 19.Приказ излаза сигнала у електричном облику

Предњи панел је примарни облик комуницирања са системом, јер се помоћу њега се подешавају циљне вредности система. Параметри PID контролера се такође могу одређивати, као што се може и пратити тренутна вредност притиска у систему.

3.5 Софтвер платформе

Софтвер коришћен у мерењима је RT650.50. Направљен је на основу SCADA ситема. Овај софтвер омогућава праћење система са рачунара. Може се користити као замена за све функције које нуди кабинет. Када повежемо платформу и рачунар уз помоћ серијске везе могуће је управљати платформом са рачунара. Ова врста управљања дозвољава стварање датотеке у којој постоје сви узорковани сигнали од управног сигнала одзива система, PID параметри. Поред контролних функција могуће је пратити и график две вредности као и одскочну вредности према којој се подешава систем. Додатно се могу мењати карактеристике графика, подешавати границе, као и временски интервал узорковања вредности сваке криве. Цела платформа на рачунару се може видети на *слици 20*.



Слика 20. Приказ Софтверске платформе са свим апликацијама и функцијама[26]

4. МАТЕРИЈАЛ И МЕТОД

4.1 Материјал

Материјал који је искоришћен за мастер рад је директно измерени сигнал помоћу софтвера RT650.50, који је дизајниран да прикупља узорке сваке секунде. Прикачен на РС користи се за израђивање базе података. Свака база података има у својим колонама: управљачки сигнал, одскочни сигнал, одзив система, и PID параметре. У овом случају електрични сигнали који долазе из одвојених излаза нису коришћени због недостатка осцилоскопа, чијим би мерењем било могуће остварити већи интервал узорковања сигнала.

Када је у питању платформа која може имати различите комбинације, као што је речено у поглављу 3, могуће су три комбинације система: са једним, дуплим и осцилаторним капацитетом. Сваки од ових процеса може имати своје одређене параметре као што су параметри PID контролера и остале сигнале за сваку једну секунду. Свака комбинација платформе снимљена је као потенцијална база података описану *табели 2*, на којој су јасно постављени параметри који карактеришу један одзив система. Као генерално правило, свака од ових одвојених комбинација PID параметара и почетног и циљног стања је снимано приближно 300 s. Као заједничку карактеристику сваки од одвојених процеса отвореност отпусног вентила је 50%. Тачније сваки процес је исти када је у питању поремећај.

Табела 2. Приказ комбинације параметара и вредности у првој варијацији модела – Варијација са једним капацитетом

Редни бр. Базе података	Вредност [bar]		PID параметри		
	Почетна	Крајна	Појачање	Интегратор	Диференцијатор
1	2	3	1	0,04	0
2	2	3	1	0,04	0,5
3	2	3	1	0,24	0
4	2	3	1	0,54	0
5	2	4	1	0,04	0
6	2	4	1	0,04	0,5
7	2	4	1	0,24	0
8	2	4	1	0,54	0
9	3	4	1	0,04	0
10	3	4	1	0,24	0
11	3	4	1	0,54	0

Било је врло важно користити разне комбинације PID параметара и комбинација почетних вредности које би могле да утичу на модел. Уз ове комбинације модел би требало боље да опонаша систем. Наравно није цела база података коришћен за тренирање модела. Потребно је поделити базу података још на елементе за валидацију и тестирање. База података је дакле подељена у следећем односу за тренирање, валидацију и тестирање на 70% - 20% - 10% респективно.

У овом раду, базе података нису коришћене на комбинацији са дуплим и осцилаторним капацитетом. Ове базе би могле касније да буду коришћене као додатна провера за модел које користимо, да би се показала флексибилност модела. Као додатак, параметри ових база се могу видети у табелама 3, 4. Ове базе могу да се користе на исти начин као прва база. Параметри ових база података су показани у табели 2 и 3.


Табела 3. Приказ комбинације параметара и вредности у другој варијацији модела – Варијација са дуплим капацитетом

Редни бр. базе података	Вредност [bar]		PID параметри		
	Почетна	Крајна	Појачање	Интегратор	Диференцијатор
1	2	3	1	0,04	0
2	2	3	1	0,04	0,5
3	2	3	1	0,24	0
4	2	3	1	0,54	0
5	2	4	1	0,04	0
6	2	4	1	0,04	0,5
7	2	4	1	0,24	0
8	3	4	1	0,54	0
9	3	4	1	0,04	0

Табела 4. Приказ комбинације параметара и вредности у трећој варијацији модела – Варијација са осцилаторним капацитетом

Редни бр. базе података	Вредност [bar]		PID параметри		
	Почетна	Крајна	Појачање	Интегратор	Диференцијатор
1	2	3	1	0	0
2	2	3	1	0,04	0,5
3	2	3	1	0,24	0
4	2	3	1	0,54	0
5	2	4	1	0	0
6	2	4	1	0,04	0,5
7	2	4	1	0,24	0
8	3	4	1	0,54	0

Пример како изгледа један график који показује одзив система, одскочну вредност и управљачки сигнал, је приказан на слици 21. Он се добија преко софтвера RT650.50.



Слика 21. Приказ одзива првог система у коме је плава крива одзив система X [bar], црвена одскочни сигнал W [bar], црна крива управљачки сигнал Y [%] отворености вентила

4.2 Метод

Као што је већ речено, кључна карактеристика у идентификацији је предзнање о процесу који се идентификује, али и искуство. Из ова два разлога, ствари постају врло сложене, јер сем чињенице да је систем другог реда, цео процес је непознат. Када се та чињеница дода са количином искуства у идентификацији, цео процес се додатно компликује па следи, као и на *слици 3*, одређена доза експериментисања. Самим тим модел који је изабран мора бити флексибилан и структурно једноставан како би лако дошли до моделираног система. Такође потребно је да сви утицају могу бити лако прилагођени моделу.

Овакви услови траже једно од универзалних апроксиматора: MLP. Овај избор одговара свим постављеним условима. Ако се користи MLP могуће је користити његову просту структуру да повећавамо флексибилност и тако да прилагодимо структуру модела систему који се идентификује. Поред тога могуће је неутралисати поремећај у случају довољно великог броја узорака.

Потребно је, додатно навестити, да је једини елемент који производи поремећај отпусни вентил. Додатних поремећаја нема, као што је у дизајну платформе гарантовано, те свако даље истраживање и експериментисање полази од ове гаранције.


Узимајући у обзир да познајемо делимично нелинеаран систем који идентификујемо, као систем другог реда могуће је користити мрежу са спољашњом динамиком и тако скратити време које би провели око одређивања стабилности модела са унутрашњом динамиком. Поред динамике модела, потребно је дефинисати која ће метода тренирања бити од користи, што зависи од линеарности/нелинеарности система.

Као решење проблема потребно је узети модел ANN-а који би савладао карактеристике процеса. Први корак је полазак од чињеница да је овај систем:

1. Динамички и
2. Нелинеаран.


Када се имају поменуте чињенице на уму, потребно је обратити пажњу на утицаје из прошлих временских интервала и на њихов редослед. Тако сама ANN са једним улазом и очекиваним излазом на основу кога базирамо идентификацију неће бити довољна. Тај закључак следи из главне карактеристике ANN-а, па тако и саме мане: концепта црне кутије. Немогуће је рећи до ког нивоа је овакав систем поуздан. Постојање могућности да ће се одређена црна кутија понашати горе под утицајем другачијих побуда је реална, упркос било каквом експерименту. Додавањем превише секвентних улаза прошлих интервала би могао да имплицира претпоставку да је овај модел зависи од више утицаја него што је то у стварности. Претеран број улаза би могао да негативно утиче на одређену динамику модела система. Тако направљен модел би изазвао грешке на местима где иста унутрашња структура слојева неурона модела са мање секвентних улаза била успешнија.

Када полазимо од чињенице да је природа овог система другог реда нелинеарна и динамична можемо почети да разматрамо модел MLP и једно од спољашњих структура наведени у другом поглављу. У случају кад би нелинеарна функција била MLP, NFIR структура самим тим није довољно добризбор јер нема у виду прошле вредности процеса који су битни. Следе преостала два модела NARX и NARXMAX. Из техничких разлога програм Matlab нема подршку за NARXMAX и тако остаје NARX као преостало решење, као на *слици 22*. На овај начин покривају се главне карактеристике система платформе, али једина ствар која преостаје је величина регресионог вектора која је потребна применити да би добили најбољи одзив.



Слика 22. Приказ NARXANN мреже[9]

Постоје двеврсте поменуте мреже који се могу користити као системи идентификације једног процеса и то су паралелна и серијски-паралелна NARX мрежа, као и на *слици 23*, десно, лево респективно. Прва врста користи сопствене вредности у регресионом вектору док друга врста користи већ измерене вредности из оригиналног система.



Слика 23. Приказ два облика архитектуре модела у NARX[9]

Када је у питању паралелна архитектура, може се видети повратна спрега са сопственим пројекцијама. Може се закључити из структуре да ће тачност модела зависити од претходних пројекција. Ова карактеристика се може сматрати проблематичном јер у случају лоше пројектоване вредности у једном тренутку. Зато што следећа пројекција мора бити базирана на претходној лошој пројекцији постаје проблем јер ће лоше вредности регресионог вектора воде ка лошој вредности предикције. Сем у случају у коме би ANN регулисала ту грешку, свака следећа вредност ће постати гора од претходне. У другом случају, серијски-паралелна NARX мрежа долази са одређеним побољшањем јер улаз који долази проистичу из реалних излаза система који преко нелинеарне карактеристике утичу на процес. На овај начин омогућује се ефикасије опонашање система, али оно што је потребно је претходно знање и регистровање излаза.

Поред регресионог вектора, преостају класични проблеми ANN-ова и то су:


1. Број улаза
2. Број неурона у скривеним слојевима
3. Број самих скривених слојева
4. Алгоритам који се користи за учење
5. Степен генерализације за време тренинга као и техника која ће тај степен осигурати и на крају
6. Подела базе података на податке који служе за тренинг, валидацију и тестирање саме NARXANN.

Поменути нелинеарни модели се могу свести концептуално на два начина идентификације: предикцију и симулацију. Предикција за n корака у будућност се своди на повећавање димензије регресионог вектора на n елемената где су укључени управљачки сигнали и прошле вредности одзива система. Симулација, са друге стране, у свом регресионом вектору користи само вредности улаза од свих сигнала система. Додатно, користи се предвиђени интервали самог система $\hat{y}$ у регресионом вектору.


Примећује се да предикција функционише само један временски интервал у будућност. Тачније без обзира колика величина регресионог вектора била предвиђа се увек један корак у будућност. Самим тим постоје одређена ограничења до којег можемо доћи само на основу модела. Ако се деси да је одређен процес врло брз и да је потребна идентификација неколико корака унапред да би се осигурало управљање процесом, овај приступ постаје проблематичан.

Као решење овом проблему могуће је редно повезати два модела за предикцију и самим тим би омогућила излаз из проблема који је наследан у облику решења. На *слици 24* графички је приказано ово решење. Као што је очигледно, једно од главних потреба у овом случају је познавати улаз који утиче на сам систем. Прогресивним редним додавањем истог овог предиктора примећује се све већа зависност од предвиђене вредности одзива модела $\hat{y}$ у различитим интервалима у времену. На овај начин разлика између предикције и симулације постаје мања.

Паралелно са овим моделом, можемо изабрати врсту хибрида који користи све улазе који се користи модел на *слици 25*. Разлика у овом случају је та да постоји један модел ANN који се користи за разлику од претходног примера где постоје две. Главна разлика између ова два приступа је та да се додатно предвиђање у будућност у првом случају решава додавањем још једног модела док у другом случају захтева поновно тренирање неке нове ANN што чини други приступ мање практичним.



Слика 24. Предикција два корака у будућности са предно повезаним серијски-паралелним моделима[9]



Слика 25 Предикција два корака у будућности са прелазним моделима[9]

4.3 Реализација процеса оптимизације

Оптимални модел за платформу је од кључног значаја. За оптимизацију MLP се користи техника раста или постепеног повећавања структуре MLP било броја неурона или слојева. Начин на који се бира оптимални модел је поређење највећег одступања од жељеног одзива. Они модели са најмањим одступањима биће изабрани као најбољи. Додатно, дискутује се о осталим моделима који најближе прате изабрана оптимална решења. Као главна база података на којој ће се вршити експериментисање бирана је верзија система са једним резервоаром у којој се сваки снимљени одзив система различит по PID параметрима и осталим карактеристикама.

Оптимизација се на почетку може поделити на два главна дела: оптимизација паралелног и серијски-паралелног модела. Прво је потребно поделити процес оптимизације на ова два дела и тек након те поделе оптимизовати засебно сваки од врста NARX MLP. Након што су оба процеса завршена њихови резултати ће се поредити.


Генерализација обе верзије архитектуре ће бити регулисана раним заустављањем. Фактор раног заустављања је на одређен број интервала у коме фактор валидаци је узастопно стагнира или смањи у квалитету. Када се тај интервал достигне учење MLP се прекида. Као предлог из [25] за алгоритам учења се опредељује за алгоритам скалиране измене градијента (ScaledConjugateGradient). Датотека из које се учи састоји се од једанаест различитих одзива система са једним резервоаром. Сваки од њих садржи приближно 300 сузоркованог одзива. Издвајањем једног одзива на коме се показује одступање остаје укупно 3000 s за учење. Збој ове великог броја узорака фактор раног заустављања је подешен на 200 интервала.

Када се заврши са постављањем услова, потребно је прећи на најбитнији део оптимизације модела: флексибилност модела. Ова карактеристика повећава се техником раста – повећавањем броја слојева и неурона у тим слојевима MLP. Повећавање слојева је генерално решење за оптимизацију ANN. Поред тога техника раста се користи на регресионом вектору. Повећање ових елемената повећава увид у проток времена у MLP. Начин на који се комбинују слојеви и борј елемената у регресионом вектору је следећи: Нека је број елемената у регресионом вектору n у коме $n = 1, 2, 3$. Структура MLP са регресионим вектором од n елемената ће имати две верзије структуре: једну са n слојева другу са $n + 1$ слојева. Сваки од ових слојева може имати m броја неурона где је $m = 3, 4, \dots, 6$. За време оптимизације у структури са одређеним бројем слојева комбиноваће се свака могућа комбинација и из тих структура издвојити оптимални модел.


Коначно, када се свака комбинација неурона у свакој комбинацији слојева са сваком комбинацијом броја елемената у регресионом вектору израчуна, можемо доћи до закључка оптималног решења за модел система.

4.4 Примена оптимизације у софтверу

Циљ софтверског решења је праћење оптимизације која је описана и претходном поглављу. Пре него што почнемо са применом принципа потребно је издојити места за све моделе који су тренирани. Када завршимо са оптимизацијом модела требало би бити могуће да издвојимо конкретан модел и да га користимо у даљим фазама у инжењерству. Дакле потребно је прво поделити моделе на паралелну и серијски-паралелну архитектуру са Syst_IdentClosed и Syst_Ident фолдерима респективно, *слика 26*. Након тога потребно је поделити комбинацију архитектуре на број елемената у регресионом вектору и број слојева, као на *слици 26*. Унутар фолдера који су означени бројем регресора и броја слојева постављене су све комбинације структура где можемо наћи све научене моделе, као на *слици 27*.



Слика 26. Приказ коначних решења задатака идентификације..



Слика 27. Приказ унутар једне групе модела система

Када први пут отворимо софтверско решење, примећујемо две главне петље. Једна која подешава борј елемената у регресионом вектору а друга број слојева у MLP, као на *слици 28*.

Слика28. Програм са затвореном главном петљом

```

13 - cElements=[];
14 - for ic=1:layer
15 -     for j=3:6
16 -         cElements = [cElements,j] ;
17 -     end
18 - end
19 -
20 - c1 = combntns(cElements,layer);
21 - c1 = sortrows(c1);
22 - c1 = unique(c1,'rows');
23 -
24 - IIIrdName=mat2str(layer);
25 - IIIrdName=strcat(IIIrdName, ' N of layers\');
26 - Tplot=[];

```

37

Након тога, за сваку структуру се одваја место, постављају услови за учење, као на *слици 30*.

```

28 - for struc=1:size(c1(:,1))
29 -     net = narxnet(d1,d2, c1(struc,:), 'open');
30 -     %net = narxnet(d1,d2, c1(struc,:), 'closed');
31 -     net=init(net);
32 -     net.divideFcn = 'dividerand';
33 -     net.trainParam.showWindow=false;
34 -     net.trainFcn = 'trainscg';
35 -     net.trainParam.max_fail=200;
36 -     net.trainParam.mu = 1;
37 -     net.trainParam.mu_dec=0.8;
38 -     net.trainParam.mu_inc=1.4;
39 -     net.trainParam.epochs = 2700;
40 -     net.trainParam.goal = 1e-5;
41 -     net.trainParam.min_step=1e-5;
42 -     dataBaseName=strcat('D:\Faks\master1\','fine_Data_I.mat');
43 -     data=load(dataBaseName);
44 -     net.trainParam.showWindow=false;

```

Слика 30.Приказ постављања свих услова за тренирање тренутне мреже

```

50 - for i=1:11
51 -     index=num2str(12-i);
52 -     dataBaseName=strcat('D:\Faks\master1\','fine_Data_I');
53 -     dataI=getfield( data, strcat('I', index) );
54 -     UI= dataI(:,3);
55 -     TI= dataI(:,1);
56 -     UI=UI';
57 -     TI=TI';
58 -     UI= mapminmax(UI);
59 -     % TI= mapminmax(TI)
60 -     UI=con2seq(UI);
61 -     TI=con2seq(TI);
62 -     if i ~=11
63 -         [Xs,Xi,Ai,Ts] = preparets(net,UI,{},TI);
64 -         UII=[UII Xs];
65 -         TII=[TII Ts];
66 -     else
67 -         [Xs,Xi,Ai,Ts] = preparets(net,UI,{},TI);
68 -         Ttest=Ts;
69 -         Utest=Xs;
70 -         Aitest=Ai;
71 -         Uitest=Xi;
72 -     end
73 - end
74 -

```

Слика 31.Приказ припреме датотека за учење

Учење се заснива на подели датотеке на податке тренинга, валидације и тестирања, слика 32, линија 76-79. Овакав приступ дозвољава поновно тренирање по потреби корисника. Научена мрежа се симулира уз помоћ датотеке за тестирање. Цела мрежа се касније чува на локацији како би могли имати приступ њеној симулацији.

```
76 - [trainInd,valInd,testInd] = dividerand(size(UII),0.7,0.2,0.1)
77 - net.divideParam.trainInd = trainInd;
78 - net.divideParam.valInd   = valInd;
79 - net.divideParam.testInd  = testInd;
80 - [net tr]=train(net, UII, TII );
81
82 - Yp=sim(net,Utest);
83 - y=cell2mat(Yp);
84 - Ttest= cell2mat(Ttest);
85 - if struc==1
86 -     Tplot=[Tplot; Ttest];
87 - end
88 - Tplot=[Tplot;y];
89
90 - IVthName=strcat( mat2str(c1(struc,:)), '\');
91 - mkdir(strcat(path, IstName, IIndName,IIIRDName,IVthName));
92 - save(strcat(path, IstName, IIndName, IIIRDName,IVthName, 'net'), 'net' );
93 - save(strcat(path, IstName, IIndName, IIIRDName,IVthName, 'tr'), 'tr' );
94 - end
```

Слика 32.Приказ учењаNARX MLP

Преостали део програма користи се за рачунање разлике између прве четири најбоље мреже у једном скупу слојева MLP и интервала у прошлости као на *слици 33*. Поред разлика показује се и највеће одступање од циљаног процеса хоризонталном линијом на којој пише структура MLP. Начин на који се то ради је да се тражи индекс мреже са најбољим перформансама. Када пронађе оптималне мреже, програм исписује њихове вредности.

```

105 - f2=figure (2)
106 - hold on
107 - f2.Units='normalized';
108 - f2.OuterPosition=[0 0 1 1];
109 - title('');
110 - hold on
111 - ylabel(' P [bar]');
112 - hold on
113 - xlabel('t [s]');
114 - hold on
115 - ax = gca;
116 - ax.FontSize = 20;
117 - hold on
118 - xlim([3 300]);
119
120
121 - legends={};
122 - MaxI = sort(Max);
123 - cIND=[];
124 - for ii=1:4...
132 - for ee=1:4
133 - plot(E(cIND(ee),:),'LineWidth',3);
134 - hold on
135
136 - end
137 - l1=string(legends{1,1});
138 - l2=string(legends{1,2});
139 - l3=string(legends{1,3});
140 - l4=string(legends{1,4});
141
142 - for ee=2:5
143 -     mname1=num2str(Max(ee-1,1));
144 -     mname=strcat( mat2str(c1(ee-1,:)),'-', mname1 );
145 -     yline(Max(ee-1,1), '-> ',mname,'LabelOrientation','aligned');
146 - end
147
148 - legend(l1,l2,l3,l4,'Location','north');
149 - hold off

```

Слика 33. Приказ рачунања и цртања разлика и максималне

Последњи задатак софтвера је цртање главних одзива како би показали њихове карактеристике када је у питању динамика и нелинеарност коју модел може имати.

Потребно је у овом циклусу погледати тачно шта је циљана вредности а шта одзиви модела тако што ће циљани модел бити пуна линија а остали испрекидане друге боје. Као почетна карактеристика постављене су пет позиција где је прва циљни процес, T . Остали одзиви модела су означени позицијама 1, 2, 3, 4. Након свих исписаних графика, сви графици су сачувани на позицијама одређеним преко структура, као на *слици 34*.

```


162 - f1=figure(1)
163 - hold on
164 - f1.Units='normalized';
165 - f1.OuterPosition=[0 0 1 1];
166 - title('');
167 - hold on
168 - ylabel(' P [bar]');
169 - hold on
170 - xlabel('t [s]');
171 - hold on
172 - ax = gca;
173 - ax.FontSize = 20;
174 - xlim([3 300])
175 -
176 - legends={};
177 - for g=1:4
178 -     if g==1
179 -         plot(Tplot(1,:), 'LineWidth',3);
180 -         end
181 -         plot(Tplot(cIND(g),:),'--','LineWidth',2);
182 -
183 -         if g==1
184 -             legends{1,g}={'T'};
185 -         end
186 -         legends{1,g+1}={char(g)};
187 -
188 -         hold on
189 -     end
190 -     l1=string(legends{1,1});
191 -     l2=string(legends{1,2});
192 -     l3=string(legends{1,3});
193 -     l4=string(legends{1,4});
194 -     l5=string(legends{1,5});
195 -     legend(l1,l2,l3,l4,l5,'Location','southeast');
196 -     save(strcat(path, IstName, IIndName, IIIRDName, 'Tplot'), 'Tplot' );
197 -     save(strcat(path, IstName, IIndName, IIIRDName, 'f1'), 'f1' );
198 -     saveas(f1, strcat(path, IstName, IIndName, IIIRDName, 'f1.png'));
199 -
200 - hold off

```


Слика 34.Приказ цртања свих потребних одзива у идентификацији

5 РЕЗУЛТАТИ И ДИСКУСИЈА

Прва доминантна разлика која се уочава је разлика између резултата модела тренирани са паралелном и серијско-паралелном архитектуром. Најбоља одступања групе паралелне архитектуре је показана *слици 35*. Можемо видети да су резултати врло лошег квалитета где оптималан модел са структуром [3-3-3-6] има највеће одступање 0,79 бар. Ако би поредили овај модел са најмање квалитетан моделом у целој групи серијско-паралелних архитектура, чије је одступање 0,2 бар, можемо закључити да је паралелна архитектура модела генерално лошија са овом структуром модела.



Слика 35. Приказ одступања паралелно тренираних модела коришћен као серијско-паралелни модел где је најмање одступања у структури 5-5-5-4




Слика 36. Приказ одзива структура најбољих структура са 4 слоја и 3 прошла секвентна интервала, позиција T) Циљна вредност процеса, 1) структура 3-3-3-6, 2) структура 3-3-3-4, 3) структура 3-3-3-5, 4) структура 5-5-5-4.

Елиминацијом паралелно тренираних модела фокус се окреће ка серијски-паралелно тренираним моделима. У првом случају у коме имамо 1 слој и 1 претходни интервал илазног и улазног параметра,можемо видети утабели 5, а одзив 4 најбоље структуре на *слици 37*.

Табела 5. *Највећа одступања структура учени серијско-паралелним моделом*

Структура ANN	Највеће одступање[bar]
4	0,0659
6	0,0948
5	0,1027
3	0,1305




Слика 37. *Приказ одзива структура са једним слојем и једним претходним временским интервалом, Позиције: T) циљана вредност, 1) структура 6, 2) структура 5 ,3)структура 3, 4) структура 4*

Као што може да се види модел са 4 неурона је најквалитетнији у односу на циљану вредност, *T*. Можемо да закључимо да су сви модели без изузетка имали највише недостатака при нелинеарном и динамичком делу што поставља закључак да није било добро претходних узорака који би задовољили нелинеарност овог система. Таква карактеристика би требало да се побољша додавањем још више узорака из прошлих интервала.

Додавањем још једног слоја у комбинацији са регресионим вектором са једним елементом можемо видети побољшање у одзиву као на слици 38, као што се може видети и побољшање у највећег одступања за дате структуре у табели 6.


Табела 6. Највећа одступања структура учени серијско-паралелним моделом

Структура ANN	Највеће одступање[bar]
3-5	0,0349
3-6	0,0682
3-3	0,1088
3-4	0,2099



Слика 38. Приказ одзива структура са два слоја и једним претходним временским интервалом, Позиције: T) циљана вредност, 1) структура 3-3, 2) структура 3-6, 3) структура 3-4, 4) структура 3-5,

Из одзива можемо закључити да се статични, линеарни део одзива показује као бољи, за разлику од претходног који је имао јасни проблем са истим, заостајћи за скоро константну вредност. Сада овај део одзива је јасно оптимизован и поклапа се са циљем. Као контраст тој чињеници, динамички и нелинеарни део одзива показује веће одступање, које није драстично веће. Из овога се може потврдити да овакав модел нема довољно вредности из претходних интервала, слика 39.




Слика 39. Приказ апсолутне разлике између циљне и добијених вредности структура

Повећавањем број регресионог вектора за један у свим комбинацијама неурона са двослојним MLP можемо видети четири најбоља одзива на слици 40. У табели 7 су показана највећа одступања ових структура.


Табела 7. Највећа одступања структура учени серијско-паралелним моделом

Структура ANN	Највеће одступање [bar]
3-4	0,0209
3-5	0,0667
3-6	0,0875
3-3	0,1110



Слика 40. Приказ одзива структура са два слоја и једним претходним временским интервалом, Позиције: T) циљана вредност, 1) структура 3-6, 2) структура 3-5, 3) структура 3-4, 4) структура 3-3,

Потврда о потреби за додатни број прошлих интервала се показала као оправдана. Када се погледају одзиви и упореде са претходним, можемо да видимо не само сличне структуре, већ и боље поклапање са првим делом целог процеса. Разлике од циљног процеса супоказане на слици 41.




Слика 41. Приказ апсолутне разлике између циљне и добијених вредности структура


Додавањем још једног слоја долазимо до 64 могућих комбинација које се све тренирају и пролазе кроз процес елиминације све до прва 4 модела. У *табели 8* као и *наслици 42,43* може се видети најбољи резултат од тренутних скупова.

Табела 8. *Највећа одступања структура учени серијско-паралелним моделом*

Структура ANN	Највеће одступање [bar]
3-3-4	0,0200
3-3-3	0,0667
3-3-6	0,0875
3-3-5	0,1110



Слика 42. *Приказ одзива структура са два слоја и једним претходним временским интервалом, Позиције: Т) циљана вредност, 1) структура 3-3-3, 2) структура 3-3-6, 3) структура 3-3-5, 4) структура 3-3-4,*




Слика 43. *Приказ апсолутне разлике између циљне и добијених вредности структура*


Додавањем још једног слоја на регресиони вектор од два елемента можемо видети погоршање када су у питању највећа одступања као што се може проверити у *табели 9*. Ако судимо по највећим одступањима резултати ових модела се погоршавају у односу на претходне. Поред овог критеријума, недостатке можемо видети и у одзиву, на *слици 44* модела, као и у одступању генерално на *слици 45*.

Табела 9. Највећа одступања структура учени серијско-паралелним моделом

Структура ANN	Највеће одступање [bar]
3-3-6	0,02044
3-3-3	0,0532
3-3-5	0,07199
3-3-4	0,0962



Слика 44. Приказ одзива структура са два слоја и једним претходним временским интервалом, Позиције: T) циљана вредност, 1) структура 3-3-3, 2) структура 3-3-6, 3) структура 3-3-5, 4) структура 3-3-4,




Слика 45. Приказ апсолутне разлике између циљне и добијених вредности структура


Код последње групе модела, узима се регресиони вектор од три елемената и структура од пет слојева MLP. Ова група има 256 комбинација које су испитане, и одступања најбоља четири модела су показана у *табели 10*, као и њихови одзиви на *слици 46* и одступања од циљане вредности на *слици 47*. Додавањем слоја у једној MLP у овом случају није показало побољшане резултате када су у питању највећа одступања у одзиву.

Табела 10. Највећа одступања структура учени серијско-паралелним моделом

Структура ANN	Највеће одступање [bar]
3-3-3-5	0,05077
3-3-3-4	0,0719
3-3-3-6	0,15761
3-3-3-3	0,1877



Слика 46. Приказ одзива структура са два слоја и једним претходним временским интервалом, Позиције: Т) циљана вредност, 1) структура 3-3-3, 2) Структура 3-3-6, 3) структура 3-3-5, 4) структура 3-3-4,



Слика 47. Приказ апсолутне разлике између циљне и добијених вредности структура

Поређење најуспешнијих модела система на основу најмањег одступања се може видети у *табели 11*. Можемо уочити шест структура где су се као најбоље показале структуре од три слоја. Након тога можемо видети да модели са два слоја показују горе резултате у мањој мери. И као највеће одступање у овој групи види се MLP са четири неурона.

Табела 11. *Најмања одступања структура учени серијско-паралелним моделом*

Структура ANN	Број елемената у регресионом вектору	Највеће одступање [bar]
3-3-4	2	0,0200
3-3-6	3	0,0204
3-4	2	0,0209
3-5	1	0,0349
3-3-3-5	3	0,0507
4	1	0,0659

Када погледамо коначне резултате, можемо видети да у случају предикције један корак у напред најбоља структура 3-5. Било какво повећање у квалитету на основу највећег одступања се мора компензовати барем додавањем још једног елемента у регресиони вектор са структуром 3-4. Када се определи за већи квалитет видимо да се структурамења само за један неурон мање у последњем слоју. Поред тога, повећава се број елемената у регресионом вектору што постаје мана. Тачније, главни проблем је тај што ће прва предикција морати да сачека два временска узорка, где је у претходном случају чекао један. Ако је услов у даљим корацима предикција на основу једног интервала побољшање квалитета није могуће. Ако се модел користи само за предикцију провећање у квалитету нема већи допринос решењу.

Са друге стране, ако наставимо да смањујемо квалитет у *табели 11* може се закључити да је разлика између оптималних модела система врло мала. Поред тога примећује се да је за врло мало побољшање у другом најбољем моделу потребно три претходна интервала. Што значи да се модел система са структуром 3-3-6 показао као знатно мање ефикасан не само у тачности већ и у времену које је потребно да један модел предвиди вредност. У најбољем моделу могуће је имати предикцију најраније након 2 s док у другом случају најранија предикција може доћи после 3 s. Када би поредили ова два оптимална решења, могли би да закључимо да је структура 3-3-4 превазилази 3-3-6 у броју неурона, у времену које је потребно за предикцију и у квалитету те предикције. Додатно када би поредили следећи модел у *табели 11* можемо закључити да сем у малој разлици у тачности структура 3-4 оптималније решење него прво у структури а дефинитивно бољи када узмемо у обзир време потребно за предикцију и сложеност модела. Исто није могуће рећи за модел 3-5 који показује знатно повећање у максималном одступању.

Са друге стране, ако је потребно извршити симулацију везивања паралелних модела, контекст се мења. У ранијем поглављу показан је пример паралелно повезаних модела како би се пробило ограничење које дозвољава само следећи корак у будућности. Овакав приступ се користи претходно предвиђеним вредностима модела како би се извела симулација до краја процеса. Када редно повежемо више истих модела можемо закључити да после одређеног броја повезаних модела престајемо да користимо узорковане вредности система. Тако, након одређеног броја повезаних модела овај процес престаје да буде предикција и претвара се у симулацију, јер се сада користи само управљачки сигнал. Следи да идентични, редно повезани модели остају у домену предикције све док број повезаних модела не превазилази број елемената у регресионом вектору.

Мана овог приступа је та да се свака даља вредност заснива на вредностима које имају одређено одступање од реалног система. Повећавање броја у ланцу модела система повећава самим тим и грешку сваке даље вредности. Другим речима, свака редна структура смањује поузданост свог крајњег решења. У том смислу, мора се изабрати модел са најмањим одступањем. Било какво веће одступање од најмањег могућег би могло негативно да утиче на одзив који би требало да опонаша одзив система. Наравно поред саме вредности система, потребно је знати и управљачки сигнал u . Овај проблем се потенцијално може симулирати преко још једног модела вишеслојног перцептрона. На овај начин додатног симулирања актуатора оставља се могућност додатног одступања од реалне вредности система ако је модел актуатора лошег квалитета.

6. ЗАКЉУЧАК

Идентификација нелинеарних система је предмет многих истраживања, анализа, синтеза итд. Коришћење ANN као модела система је широко прихваћена метода у техникама идентификације. ANN долазе у разним облицима и користе се зависно од специфичног система кога је потребно идентификовати. Како се долази до нових истраживања квалитет модела система постаје све већи чак и када је реч о нелинеарним системима. Различите врсте ANN у комбинацији са другим облицима модела повећавају способности ANN модела у идентификацији. У неким случајевима ANN коришћене са одређеном алгоритмом могу делимично да оповргну неке од утемељених закључка вештачке интелигенције.

У овом мастер раду идентификован је нелинеарни систем другог реда применом MLP модела. Платформа за идентификацију G.U.N.T. Trainer Pressure Control RT532 омогућава додавање и прераспodelу одређених елемената система што значи да се за сваки додат или прераспoreђени елемент добија нови систем. Главну улогу, када је ова карактеристика платформе у питању, имају вентили који пропуштају ваздух у резервоаре. Ако ограничимо вентиле на два стања: отворен/затворен платформа се може свести на три система. Од та три случаја један је изабран као систем за идентификацију.

База података узоркованих улаза и излаза је разнолика. Коришћене су комбинације почетних и циљних вредности система са различитим параметарима PID контролера. Тако, уз различите вредности важних сигнала, моделу је омогућено да боље опонаша систем.

Модели који су коришћени за идентификацију су NARX MLP. Главни елементи у овом моделу су величина регресионог вектора, број слојева у MLP као и број неурона у слојевима MLP. Ови елементи одређују тачност модела што се показало разним комбинацијама у току процеса оптимизације.

Раст, као метод оптимизације, се показао као брзо решење у проналажењу оптималног модела. Приступ оптимизовања модела техником раста показује добре резултате код изабраних модела. Максимално одступање модела не излазе из спектра од 0,02 до 0,0659 bar. Зависно од сврхе процеса идентификације, може се бирати између модела са већим или мањим максималним одступањем.

Ако је сврха модела предвиђање вредности система за један корак у будућност модел са структуром 3-5 се може изабрати као решење. Наравно, под условом да је за критеријум, према коме се бира модел, прихватљиво максимално одступање од 0,0349 bar. У случају да ово одступање није прихватљиво, може се изабрати квалитетнији модел структуре 3-4 чије је максимално одступање 0,0209 bar. Једина битна промена која се примећује је повећање елемената у регресионом вектору. За разлику од претходног модела, коме је потребна само једна прошла вредност одзива, нови модел захтева две прошле вредности како би предвидела одзив у будућности. Значи да је за модел 3-4 потребно да прође 2 s. Дакле, повећање у квалитету модела се мора надоместити временом које је потребно да би се дошло до квалитетније вредности. Ако је број елемената у регресионом вектору неприхватљив или тачније ако потребна ранија предикција, мора се изабрати сложенији модел од NARX MLP.

Када је сврха модела предвиђање више корака у будућности у избору модела потребно је обратити пажњу нагомилавање грешке при предикцији. Тачније, предвиђање више корака у будућност подразумева редно везивање копија једног истог модела. Показало се у мастер раду да свако предвиђање носи са собом одступање од жељене вредности након

предикције. Зато што се у редно везаном систему након сваког корака грешка нагомилава, мора се обратити додатна пажње на одступање модела. Дакле, употребом модела 3-3-4 је, у овом случају, најприкладније јер тај модел има најмање одступање од свих осталих модела.

Такође, потребно је приметити да број параметара у регресионом вектору одређује домет корака који један модел може да предвиди у будућности. Када се редно повеже више модела од броја у регресионом вектору, ради предвиђања, почињемо да симулирамо систем. Ова разлика је битна зато што више не користимо реалне вредности излаза него само пројектоване вредности предикције. Самим тим, процес се претвара у симулацију. У случају да је сврха идентификације симулација система, слични критеријуми важе као код предикције. Што занчи да је најбољи модел за симулацију структура 3-3-4.

Можемо да закључимо да идентификација система у великој мери зависи од сврхе идентификовања. Било она предикција једног или више корака или симулација потребно је обратити пажњу на максимално одступање од жељене вредности као и о броју елемената у регресионом вектору. Ако сврха идентификације захтева боље моделе чије је максимално одступање мање од 0,02 бар потребно је изабрати флексибилнију врсту модела. У супротном наведени модели су најбоље решење.

Даље истраживање би требало да идентификује остала два случаја система који су предложени. Као решење, могао би да се усвоји један NARX MLP модел који би могао да идентификује сва три случаја. За овакво решење није потребно претходно одређивање који је систем у питању. Коришћење једног модела нас ослобађа додатног проверавања и дозвољава да аутоматски остваримо било коју сврху идентификације.

Литература:

- [1] Ковачевић, Б., Квашчев Г., - Идентификација процеса, Универзитет у Београду, Електротехнички факултет 2018.
- [2] Isermann, R., Munchhof, M., Identification of Dynamic Systems: An Introduction with Applications, Springer, 2011.
- [3] Haykin, S., Neural Networks and Learning Machines, 3rd edition, Prentice Hall, 2008.
- [4] Liu, G.P, Nonlinear Identification and Control: A Neural Network Approach, Springer, 2001.
- [5] Norgaard M., Ravn O., Poulsen K., Hansen, L.K., Neural Networks for Modelling and Control of Dynamic Systems: A Practitioner's Handbook, Springer, 2003.
- [6] Kwok, N., Ha, Q., Nguyen, T., Samali J., Li, B., A novel hysteretic model for magnetorheological fluid dampers and parameter identification using particle swarm optimization, *Sensors Actuators A: Phys.* 132 (2) pp. 441–451, 2006.
- [7] W. Gong, Z. Cai, D. Liang, “Engineering optimization by means of an improved constrained differential evolution”, *Computer Methods in Applied Mechanics and Engineering*, Volume 268, pp. 884-904, 1st January 2014
- [8] Kateris, D., Moshou, D., Pantazi, X., E., Gravalos I., Sawalhi N., Loutridis S., “A machine learning approach for the condition monitoring of rotating machinery”, *Journal of Mechanical Science and Technology*, Volume 28, Issue 1, pp. 61–71, 2014
- [9] Nelles, O., Nonlinear System Identification: From Classical Approaches to Neural Networks and Fuzzy Models, Springer Science & Business Media, 2001.
- [10] Li F., Qiao J., Hana, H., Yanga, C., “A self-organizing cascade neural network with random weights for nonlinear system modeling”, *Applied Soft Computing*, Issue 42 pp. 184–193, 2016.
- [11] Hichem L., Nouri K., Braiek, N. B., “A new efficient hybrid intelligent method for nonlinear dynamical systems identification: The Wavelet Kernel Fuzzy Neural Network”, *Commun Nonlinear Sci Numer Simulat*, Issue 32, pp. 10–30, 2016.
- [12] Ayala H., V., H., Coelho, L., “Cascaded evolutionary algorithm for nonlinear system identification based on correlation functions and radial basis functions neural networks”, *Mechanical Systems and Signal Processing*, Volumes 68–69, pp 378-393, 2016

- [13] Romero, H. M., Ugalde, J., Carmona C., Alvarado, V., M., Reyes-Reyes J., Neural network design and model reduction approach for black box nonlinear system identification with reduced number of parameters, *Neurocomputing* Issue 101, pp. 170–180, 2013.
- [14] Ugalde, H., Romero, M., Carmon, J., Reyes-Reyes J., Alvarado V. M., Mantilla J., - “Computational cost improvement of neural network models in black box nonlinear system identification“, *Neurocomputing*, Issue 166, 96–108, 2015.
- [15] Tutunji, T. A., “Parametric system identification using neural networks“, *Applied Soft Computing*, Issue 47, pp. 251–261, 2016.
- [16] Pham, D. T., - *Neural Networks for Identification, Prediction and Control*, London Berlin Heidelberg New York, Springer 1995.
- [17] Patan, K., - *Artificial Neural Networks for modeling and Fault Diagnosis of Technical Processes*, Lecture Notes in Control and Information Sciences, Springer 2008.
- [18] Ранковић, В., *Интелигентно управљање*, Универзитет у Крагујевцу, Машински факултете у Крагујевцу 2008.
- [19] Jin, L., Nikiforuk, P.N., Gupta, M.M.: Approximation of discrete-time statespace trajectories using dynamic recurrent neural networks. *IEEE Transactions on Automatic Control* 1995.
- [20] Lawler, E.L. and Wood, E.D. “Branch-and-bound methods“C: *A survey. Journal of Operations Research*, pp14, 1966.
- [21] Fahlman, S., E., Lebiere, C., *The cascade-correlation learning architecture, Advances in Neural Information Processing Systems*“, volume 2, San Mateo, 1990.
- [22] Karnin E.D. „A simple procedure for pruning back-propagation trained neural Networks“. *IEEE Transactions on Neural Networks*, 1990.
- [23] Reed, R. „Pruning algorithms: A survey“. *IEEE Transactions on Neural Networks*, 1993.
- [24] G.U.N.T. HAMBURG- *Trainer Pressure Control – Experimental Instructions*, G.U.N.T. Garatebau, GmbH, Germany 2004.
- [25] Demuth, H., Beale M., - *Neural Network Toolbox: For use with Matlab, Version 4*, The MathWorks Inc, 2004.

[26] G.U.N.T. - Trainer Pressure Control [На мрежи] Доступно на:
<https://www.gunt.de/en/products/mechatronics/automation-and-process-control-engineering/simple-process-engineering-control-systems/pressure-control-trainer/080.53200/rt532/glct-1:pa-148:ca-83:pr-1187> [20.06.20019.]

[27] Spirax Sarco, Inc., Product Handbook – 2nd edition, Spirax Sarco United States of America, 5/2016

[28] Parr, A., Hydraulics and Pneumatics: A Technician's and Engineer's Guide, 2nd edition, Butterworth Heinemann, Oxford Great Brittan UK, 1999.