



KAUNO TECHNOLOGIJOS UNIVERSITETAS
ELEKTROS IR ELEKTRONIKOS FAKULTETAS

Edvinas Vaičekauskis

MODELIU PROGNOZUOJAMO VALDYMO ALGORITMŲ
EFEKTYVUMO TYRIMAI

Baigiamasis magistro projektas

Vadovas

Prof. dr. Rimvydas Simutis

KAUNAS, 2017

KAUNO TECHNOLOGIJOS UNIVERSITETAS
ELEKTROS IR ELEKTRONIKOS FAKULTETAS
AUTOMATIKOS KATEDRA

MODELIU PROGNOZUOJAMO VALDYMO ALGORITMŲ
EFEKTYVUMO TYRIMAI

Baigiamasis magistro projektas
Valdymo technologijos (621H66001)

Vadovas

Prof. dr. Rimvydas Simutis

Recenzentas

Doc. dr. Vygandas Vaitkus

Projektą atliko

Edvinas Vaičekauskis

KAUNAS, 2017



KAUNO TECHNOLOGIJOS UNIVERSITETAS

Elektros ir elektronikos fakultetas

(Fakultetas)

Edvinas Vaičekauskis

(Studento vardas, pavardė)

Valdymo technologijos (621H66001)

(Studijų programos pavadinimas, kodas)

Baigiamojo projekto „Modeliu prognozuojamo valdymo algoritmų efektyvumo tyrimai“

AKADEMINIO SAŽININGUMO DEKLARACIJA

20 17 m. gegužės 26 d.
Kaunas

Patvirtinu, kad mano **Edvino Vaičekauskio** baigiamasis projektas tema „Modeliu prognozuojamo valdymo algoritmų efektyvumo tyrimai“ yra parašytas visiškai savarankiškai, o visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

Aš suprantu, kad išaiškėjus nesąžiningumo faktui, man bus taikomos nuobaudos, remiantis Kauno technologijos universitete galiojančia tvarka.

(vardą ir pavardę įrašyti ranka)

(parašas)

Vaičekauskis, Edvinas. Modeliu prognozuojamo valdymo algoritmų efektyvumo tyrimai. *Valdymo sistemų magistro* baigiamasis projektas / vadovas prof. dr. Rimvydas Simutis; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas, Automatikos katedra.

Mokslo kryptis ir sritis: Elektros ir elektronikos inžinerija, Technologiniai mokslai

Reikšminiai žodžiai: *modeliu prognozuojamas valdymas, PID reguliatorius, neuroniniai tinklai, algoritmai.*

Kaunas, 2017. 67 p.

SANTRAUKA

Baigiamojo magistro projekto tikslas – atlikti modeliu prognozuojamo valdymo algoritmų efektyvumo tyrimus MATLAB programos paketu.

Šiame projekte apžvelgiama modeliu prognozuojamo valdymo metodologija, algoritmų vystymosi raida ir pagrindinės valdymo strategijos, kurios plačiausiai taikomos praktikoje. Išanalizuojami objekto neuroninių tinklų sudarymo principai bei jų taikymas objektų modelių identifikavimui.

MATLAB/SIMULINK programos paketu atliekami modeliu prognozuojamo valdymo algoritmų taikymai nesudėtingų ir netiesinių procesų valdymui. Taikant grafinius metodus iš šuolinės reakcijos kreivės identifikuojami objektų perdavimo funkcijų parametrai, kurie naudojami PID reguliatoriaus derinimui. Atliekamas MPC ir PID reguliatorių rezultatų/valdymo kokybės palyginimas, kai objekto modelis yra: pirmosios eilės su vėlavimu perdavimo funkcija, antrosios eilės su vėlavimu perdavimo funkcija bei dviejų talpų procesas.

Vaičekauskis, Edvinas. Investigation of Efficiency of Model Predictive Control Algorithms. *Master's thesis in Control Systems* / supervisor prof. dr. Rimvydas Simutis; Kauno University of Technology, Faculty of Electrical and Electronics Engineering, Department of Automation.

Research area and field: Electrical and Electronics Engineering, Technological Sciences

Key words: *model predictive control, PID controller, neural network, algorithms.*

Kaunas, 2017. 67 p.

SUMMARY

The aim of Master's final project is to perform investigation of efficiency of model predictive control algorithms.

In this project the methodology of model predictive control is reviewed. Development of algorithms and the main control strategies which are the most commonly applied in practice are analyzed. Analysis of formation of neural network and their application for identification of plant models is performed.

Application of algorithms of model predictive control for control of typical and nonlinear processes is performed using MATLAB/SIMULINK software. Plant parameters of transfer functions are identified for adjustment of PID controller using step function method. Comparison of performance/control quality of MPC and PID controller is carried out when plant model is: first order transfer function with time delay, second order transfer function with time delay and two-tank system process.

TURINYS

SANTRUMPŲ IR ŽENKLŲ AIŠKINIMO ŽODYNAS	8
ĮVADAS	9
1. LITERATŪROS APŽVALGA	10
1.1 Modeliu prognozuojamo valdymo apžvalga.....	10
1.2 Modeliu prognozuojamo valdymo metodai	12
1.2.1 Dinaminis matricinis valdymas	12
1.2.2 Modelio algoritminis valdymas.....	14
1.2.3 Prognozuojamas funkcinis valdymas	15
1.2.4 Išplėstinės prognozės savaimė prisitaikantis valdymas	17
1.2.5 Išplėstinio laikotarpio adaptyvus valdymas	18
1.2.6 Apibendrintas prognozuojantis valdymas	19
1.3 Neuroninio tinklo modelių prognozuojamas valdymas	20
1.3.1 Sistemos identifikavimas.....	20
1.3.2 Prognozuojamas valdymas	21
2. PIRMINIS MPC ALGORITMŲ TAIKYMAS NESUDĖTINGŲ TIPINIŲ PROCESŲ VALDYMUI	22
2.1 Objekto modelis – Pirmosios eilės perdavimo funkcija su vėlavimu	22
2.2 Objekto modelis – Antrosios eilės perdavimo funkcija su vėlavimu	27
3. MPC ALGORITMŲ TAIKYMAS NETIESINIŲ PROCESŲ VALDYMUI.....	29
3.1 Dviejų talpų modelis	29
4. MPC REZULTATŲ/VALDYMO KOKYBĖS Palyginimas su klasikiniais PID REGULATORIAIS	33
4.1 Pirmosios eilės perdavimo funkcija su vėlavimu.....	33
4.1.1 MPC ir PID regulatoriaus rezultatų/valdymo kokybės palyginimas (derinimas trikdžio atžvilgiu).....	33
4.1.2 MPC ir PID regulatoriaus rezultatų/valdymo kokybės palyginimas (derinimas nuostato atžvilgiu).....	39
4.2 Antrosios eilės perdavimo funkcija su vėlavimu	42
4.2.1 Antrosios eilės su vėlavimu perdavimo funkcijos parametrų identifikavimas iš šuolinės reakcijos kreivės	42
4.2.2 MPC ir PID regulatoriaus rezultatų/valdymo kokybės palyginimas (derinimas trikdžio atžvilgiu).....	44
4.2.3 MPC ir PID regulatoriaus rezultatų/valdymo kokybės palyginimas (derinimas nuostato atžvilgiu)	49
4.3 Dviejų talpų procesas	52

4.3.1 Dviejų talpų proceso modelio parametrų identifikavimas iš šuolinės reakcijos kreivės.....	52
4.3.2 MPC ir PID regulatoriaus rezultatų/valdymo kokybės palyginimas (derinimas trikdžio atžvilgiu).....	54
4.3.3 MPC ir PID regulatoriaus rezultatų/valdymo kokybės palyginimas (derinimas nuostato atžvilgiu).....	59
REZULTATAI IR IŠVADOS	63
INFORMACIJOS ŠALTINIŲ SĄRAŠAS.....	65

SANTRUMPŲ IR ŽENKLŲ AIŠKINIMO ŽODYNAS

PID – Proporcinis, integruojantis ir diferencijuojantis

MPC (angl. *Model predictive control*) – Modeliu prognozuojamas valdymas

DMC (angl. *Dynamic matrix control*) – Dinaminis matricinis valdymas

MAC (angl. *Model algorithmic control*) – Modelio algoritminis valdymas

PFC (angl. *Predictive functional control*) – Prognozuojamas funkcinis valdymas

EPSAC (angl. *Extended prediction self-adaptive control*) – Išplėstinės prognozės savaimė prisitaikantis valdymas

EHAC (angl. *Extended horizon adaptive control*) – Išplėstinio laikotarpio adaptyvus valdymas

GPC (angl. *Generalized predictive control*) – Apibendrintas prognozuojantis valdymas

MV (angl. *Minimum variance*) – Minimalus nuokrypis

GMV (angl. *Generalized minimum variance*) – Neapibrėžtas minimalus nuokrypis

MPHC (angl. *Model Predictive Heuristic Control*) – Modelio prognozuojamas euristinis valdymas

CARIMA (angl. *Integrated controlled auto regressive moving average*) – Integruotas valdomas autoregresijos slenkantis vidurkis

NN (angl. *Neural Network*) – Neuroninis tinklas

ISE (angl. *Integral of the Square of the Error*) – Kvadratinės paklaidos integralas

IAE (angl. *Integral of the Absolute value of the Error*) – Absoliutinės paklaidos integralas

IVADAS

Didžiulės inžinerinės sistemos dažniausiai susideda iš daugybės posistemų, kurios sąveikaudamos tarpusavyje sąlygoja medžiagų, energijos ir informacijos srautų rezultatus. Aukštos kokybės valdymo technologijos, kaip modelių prognozuojamas valdymas, yra naudojamos šioms posistemėms valdyti.

Modelių prognozuojamas valdymas yra sėkminga valdymo strategija, kuri atsirado 8-ajame dešimtmetyje siekiant spręsti pramonės valdymo užduotis. Šio metodo pagrindas – panaudoti tinkamą proceso modelį ir jo prognozuojančias savybes proceso valdymo algoritmų formavimui. Proceso modelis yra taikomas apskaičiuoti prognozuojamus išėjimus ar būsenas, kurie yra naudojami objekto nuostolių funkcijos minimizavimui bei valdymo algoritmų prognozavimui numatytoje prognozavimo srityje.

Projekto tikslas – atlikti modelių prognozuojamo valdymo algoritmų efektyvumo tyrimą MATLAB programos paketu.

Projekto uždaviniai:

1. išanalizuoti modelių prognozuojamo valdymo metodologiją;
2. suformuoti objektų matematinius (juodos dėžės) modelius, kurie bus naudojami modelių prognozuojamo valdymo algoritmuose;
3. atlikti modelių prognozuojamo valdymo algoritmų tyrimus, taikant juos įvairiems objektams;
4. palyginti modelių prognozuojamo valdymo algoritmų rezultatus su klasikiniais PID reguliatoriais.

1. LITERATŪROS APŽVALGA

1.1 Modeliu prognozuojamo valdymo apžvalga

Modeliu prognozuojamas valdymas (angl. *Model predictive control, MPC*) yra reguliatorių šeima, kuri sukuria aiškų modelio panaudojimą gauti valdymo signalui. Šio metodo populiarumo pramonėje ir mokslinėje veikloje pagrindas yra sugebėjimas dirbti ilgame periode be ekspertų įsikišimo. Įvairūs valdymo metodai remiasi modeliu prognozuojamo valdymo koncepcija. Pramonėje įsitvirtinusios ir plačiausiai naudojamos modeliu prognozuojamo valdymo strategijos yra: *Dinaminis matricinis valdymas* (angl. *Dynamic matrix control, DMC*), *Modelio algoritminis valdymas* (angl. *Model algorithmic control, MAC*), *Prognozuojamas funkcinis valdymas* (angl. *Predictive functional control, PFC*), *Išplėstinės prognozės savaimė prisitaikantis valdymas* (angl. *Extended prediction self-adaptive control, EPSAC*), *Išplėstinio laikotarpio adaptyvus valdymas* (angl. *Extended horizon adaptive control, EHAC*) ir *Apibendrintas prognozuojantis valdymas* (angl. *Generalized predictive control, GPC*) [1].

Per pastaruosius du dešimtmečius buvo domimasi pažangių procesų valdymo plėtra ir jų tobulinimu. Septintajame dešimtmetyje pažangiu valdymu buvo laikomas apskritai bet koks algoritmas, kuris skyrėsi nuo klasikinio PID reguliatoriaus. Kokybiškam, saugiam ir ekonomiškam procesui PID reguliatoriai apėmė daugiau nei 80 % visų pramonės procesuose įdiegtų automatikos valdymo įrenginių [2].

Pagrindiniai PID reguliatorių automatinio reguliavimo metodai rėmėsi modelio atpažinimu arba perdavimo funkcijomis, gautomis iš reakcijų kreivių. Naudojantis šiais metodais rezultatai yra geresni nei rankiniu būdu suregulius PID parametrus. Vis dėlto, pagrindinis PID reguliatorių principas nėra efektyvus, kai procesas pasiekia kritinius nukrypimus nuo darbo taško.

Taip pat yra ir kitų metodų, kurie buvo naudojami kaip savaimė susireguliuojantys reguliatoriai: *Minimalaus nuokrypio metodas* (angl. *Minimum variance, MV*), *Smito prognozės, neapibrėžto minimalaus nuokrypio metodas* (angl. *Generalized minimum variance, GMV*). Pasirinkus tinkamus parametrus šie metodai pasiekia labai aukštus valdymo kokybės rezultatus.

Minimalaus nuokrypio *MV* apribojimas yra tas, kad šis metodas negali dirbti ir reikalauja pernelyg didelių valdymo pastangų ne minimalios fazės sistemoje, o neapibrėžto minimalaus nuokrypio metodas *GMV* reikalauja mažiau valdymo pastangų ir susitvarko su ne minimalios fazės sistema.

Keletas *GMV* modifikacijų lėmė modeliu prognozuojamo valdymo plėtrą, kuri buvo plačiai taikoma pramonėje. *MPC* pritraukė daugybę mokslininkų dėl didesnio efektyvumo ir

geresnio procesų valdymo, įskaitant ne minimalią fazę, didelį vėlinimą ar atvirosios valdymo sistemos nestabilias charakteristikas, negu *MV* ir *GMV* metodai [1][3].


Pagrindinis modeliu prognozuojamo valdymo privalumas lyginant su PID reguliatoriais yra sugebėjimas valdyti apribojimus, ne minimalios fazės procesus, sistemos parametru pasikeitimus bei paprastas pritaikymas dideliems, daug kintamųjų turintiems procesams.

Modeliu prognozuojamas valdymas taip pat žinomas kaip besikeičiančios srities valdymas, kuris apima grupę valdymo metodų ir yra naudojamas numatyti dinaminų modelių manipuluojamų kintamųjų reakcijų pasikeitimus išėjime bei gauti valdymo signalą remiantis nuostolių funkcijos mažėjimu. Reguliatoriaus efektyvumas priklauso nuo to, kaip gerai sistemos dinamika atkartoja įėjimų-išėjimų modelį, kuris buvo naudojamas reguliatoriaus kūrimui.

Modeliu prognozuojamas valdymas dažniausiai apima šias tris sąvokas [4]:

1. Aiškus modelio panaudojimas norint numatyti proceso išėjimą būsimo laiko srityje;
2. Valdymo sekos skaičiavimas norint optimizuoti kokybės rodiklį;
3. Besikeičiančios srities strategija – kiekvienu laiko momentu sritis juda į būsimą tašką, kuris apima kiekvienu žingsniu apskaičiuotos sekos pirmą valdymo signalo taikymą.

Modeliu prognozuojamo valdymo besikeičiančios srities strategija atvaizduojama 1.1 paveiksle [1].



1.1 pav. MPC besikeičiančios srities strategija

1. Proceso modelis skaičiuoja prognozuojamus išėjimus $\hat{y}(t + j / t)$, $j = 1, \dots, N - 1$ prognozavimo srities N kiekvienu laiko momentu t . Išėjimai priklauso nuo žinomų reikšmių iki apskaičiuoto laiko momento t (ankstesni įėjimai ir išėjimai), apimant esamą išėjimą (pradinė sąlyga) $y(t)$ ir būsimumus valdymo signalus $u(t + j / t)$, $j = 0, N - 1$.
2. Būsimų valdymo signalų seka yra apskaičiuojama optimizuoti valdymo kokybės rodiklį.

3. Tik esamas valdymo signalas $u(t / t)$ yra siunčiamas procesui. Kitos imties laiko momentas $y(t + 1)$ yra įvertinamas ir pirmasis žingsnis kartojamas tol, kol atliekamos visos sekos. Tokiu būdu $u(t + 1 / t + 1)$ yra apskaičiuojamas naudojant besikeičiančios srities strategiją [5].

Modeliu prognozuojamame valdyme proceso modeliai, naudojami sistemos kokybės analizei ir nuo kurių priklauso valdymo efektyvumas, yra tiesiniai arba netiesiniai. Būsimos manipuliuojamų kintamųjų pozicijos yra nustatomos naudojant minimizuotą prognozavimo paklaidą arba objekto funkciją.

1.2 Modeliu prognozuojamo valdymo metodai

Yra įvairių valdymo metodų pagrįstų modeliu prognozuojamo valdymo koncepcija. Toliau apžvelgiama šešių dažniausiai taikomų metodų istorija, pagrindinė idėja, glaustas pagrindinių principų ir formulavimo aprašymas, pagrindinės savybės, privalumai bei trūkumai.

1.2.1 Dinaminis matricinis valdymas

1979 metais, inžinieriai Culteris ir Ramakeris iš „Shell Oil“ kompanijos pristatė neapribotą kelių kintamųjų valdymo algoritmą, kurį jie pavadino *Dinaminium matriciniu valdymu* (angl. *Dynamic matrix control, DMC*). Šis algoritmas išsiplėtojo iš atvaizduojamos proceso dinamikos su skaitmeninių koeficientų technika. Dinaminė matrica yra naudojama planuoti būsimus išėjimus. Ji tinkama tiesiniam atviro kontūro stabiliam procesui. *DMC* metodas yra pagrįstas proceso žingsnio atsako modeliu [6].

DMC regulatoriaus tikslas yra valdyti išėjimą taip, kad jis sektų užduotą vertę naudojant mažiausių kvadratų metodo reikšmę, kuri apima baudos sąlygas įėjimo pasikeitimui. Tai sąlygoja mažesnius apskaičiuotus įėjimo pasikeitimus ir tolydesnį išėjimo atsaką.

Taikant vieno įėjimo ir vieno išėjimo (angl. *Single input single output, SISO*) atvejį, objekto žingsnio atsako modelis aprašomas [7]:

$$y(t) = \sum_{i=1}^{\infty} g_i \Delta u(t - i). \quad (1.1)$$

Trikdis laiko momentu t per visą laikotarpį yra:

$$\dot{x}\left(t + \frac{j}{t}\right) = \dot{x}\left(\frac{t}{t}\right) = e(t) = y_m(t) - \dot{y}\left(\frac{t}{t}\right). \quad (1.2)$$

Prognozuojama vertė per visą laikotarpį bus:

$$\dot{y}\left(t + \frac{j}{t}\right) = \sum_{i=1}^{\infty} g_i \Delta u(t + j - i) + \dot{x}\left(t + \frac{j}{t}\right). \quad (1.3)$$

Pastovaus trikdžio išėjimo prognozuojama vertė:

$$\dot{y}\left(t + \frac{j}{t}\right) = \sum_{i=1}^j g_i \Delta u(t + j - i) + f(t + j). \quad (1.4)$$

Antroji (1.4) lygties sąlyga yra laisvas narys, kuris nepriklauso nuo būsimų valdymo veiksmų. Prognozė per visą prognozuojamą laikotarpį p ir m valdymo poveikiai yra:

$$\dot{y}\left(t + \frac{p}{t}\right) = \sum_{i=p-m+1}^p g_i \Delta u(t + p - i) + f(t + p). \quad (1.5)$$

Minimizuota nuostolių funkcija, apimanti valdymo poveikius yra:

$$J = \sum_{j=N_1}^{N_2} \delta(j) \left[\dot{y}\left(t + \frac{j}{t}\right) - w(t + j) \right]^2 + \sum_{j=1}^{N_u} \lambda(j) [\Delta u(t + j - 1)]^2. \quad (1.6)$$

Be apribojimų, nuostolių funkcija aprašoma:

$$J = ee^T + \lambda uu^T. \quad (1.7)$$

Kai apribojimai yra taikomi įėjime ir išėjime, sekanti lygtis privalo būti minimizuota:

$$\sum_{j=1}^N C_{y_j}^i \dot{y}\left(t + \frac{j}{t}\right) + C_{u_j}^i u(t + j - 1) + c^i \leq 0, \quad \text{kai } i = 1, \dots, N_c. \quad (1.8)$$

Kai metodas praplečiamas iš *SISO* į kelių įėjimų-išėjimų (angl. *Multi input multi output*, *MIMO*) objektą, svarbus tik žymėjimas. Kelių kintamųjų atveju, objekto išėjimo lygtis gali būti aprašyta:

$$y_j(t) = \sum_{k=1}^{n_u} \sum_{i=1}^{N_k} g_i^{kj} u^k(t - i). \quad (1.9)$$

DMC valdymo laikotarpio ir baudos skyrimo faktorius yra reguliuojantis parametras. Formuluoiant mažiausių kvadratų metodą, baudos skyrimo faktorius įvedamas sušvelninti valdymo signalą. Standartinis kvadratinio efektyvumo rodiklis (angl. *Quadratic Performance*, *QP*) kiekvienu imties laiko momentu vykdo optimizavimą. Pagal besikeičiančios srities strategiją, laiko momentu t , tik pirmasis būsimo valdymo padidėjimo vektoriaus įėjimas ($\Delta u(t)$) arba seka (u) yra faktiškai taikomas objektui. Likę optimalūs įėjimai yra atmetami ir nauja optimali valdymo užduotis yra išsprendžiama laiko momentu $t+1$.

DMC naudojama valdymo sandara yra nepriklausoma nuo transportinio vėlinimo ir ji susitvarko su apribojimais. Trikdžio atveju, tiesioginio valdymo sistema gali būti lengvai realizuojama. Tai neturi įtakos modelio paklaidai, tačiau taikymas yra apribotas atviro kontūro ribinio įėjimo ir ribinio išėjimo (angl. *Bounded input bounded output*, *BIBO*) stabiliam proceso tipui. *DMC* algoritmo stabilumui naudojant uždaro kontūro sistemą reikalingas ilgas prognozavimo laikotarpis [8].

DMC efektyvumas yra prastas naudojant interaktyvius kelių kintamųjų objektus, kai šuoliniai trikdžiai veikia objekto išėjimą ir pokyčiai proceso dinamikoje tampa dideli.

Tuo atveju, kai atviro kontūro laiko pastovioji yra kur kas didesnė nei norima uždaro kontūro laiko pastovioji, didelis žingsnio atsako koeficientų skaičius yra reikalingas norint pagerinti grįžtamojo ryšio savybes.

Dinaminio matricinio valdymo metodas yra ypač sėkmingas naudojant kelių kintamųjų naftos chemijos pramonės procesuose [9].

1.2.2 Modelio algoritminis valdymas

Modelio algoritminis valdymas (angl. *Model algorithmic control, MAC*), kurio programinė įranga vadinama identifikavimo komanda (angl. *Identification command, IDCOM*), iš pradžių vadinosi modelio prognozuojamas euristinis valdymas (angl. *Model Predictive Heuristic Control, MPHC*). 1978 metais, Richaletas aprašė sėkmingą *MPHC* taikymą. *MPHC* naudoja impulsinio atsako modelį. Šis metodas yra labai panašus į *DMC* išskyrus šiuos skirtumus:

- Vietoj žingsninio atsako modelio Δu , impulsinio atsako modelis yra naudojamas įtraukiant u . Jei įėjimui u yra taikoma bauda, tai reguliatorius nepašalina kompensacijos. Jei įėjimui u nėra taikoma bauda, tuomet būtinos labai sudėtingos procedūros norint apdoroti ne minimalios fazės sistemas;
- Įėjimo pasikeitimo skaičius nenaudojamas reguliuoti;
- Trikdžio įvertinimas $x(t + j/t)$ yra nufiltruojamas.

Kelių kintamųjų proceso valdymas yra atvaizduojamas impulsinių atsakų naudojant realaus laiko duomenis prognozei. Šis vidinis modelis yra nuolat atnaujinamas naudojant objekto darbinis duomenis su identifikavimu – eksperimentinių duomenų identifikavimas diskretiniais laiko momentais yra tikslus valdymo tikslui ir realaus laiko identifikavimo procesas naudojamas, jei pasikeitimai objekte yra staigūs ir atsitiktiniai, bet tai yra brangu ir sudėtinga.

Tai apibūdina nuorodos trajektoriją kaip pirmos eilės sistemą, kuri pagal nustatytą laiko pastoviąją išsiplėtojo iš realaus užduotos vertės išėjimo. Uždaro kontūro sistemos elgsena yra priskiriama nuorodos trajektorijai ir ji valdo algoritmo tolydumą. Jei nuorodos trajektorija yra kur kas greitesnė nei procesas, tuomet *MPHC* metodas nebus efektyvus. Todėl laiko pastovioji yra pagrindinis nuorodos trajektorijos parametras [10].

Valdymas yra apskaičiuojamas naudojant pasikartojančią procedūrą – vertinant keletą bandymų, kad apskaičiuoti geriausią įėjimą sekimo paklaidos minimizavimui nepakenkiant vykdykliams ir proceso valdymo skaičiavimo įrangai. Būsiami įėjimai, kai yra taikomi greitai

besikeičiančiam vidiniam prognozuojamam modeliui, išėjimai turi būti kuo artimesni numatyta nuorodos trajektorijai.

MAC metode, impulsinis atsakas leidžia sustiprinti trikdžius prieš identifikuojant paklaidas. Modeliavimo paklaidos parametų trikdymo efektas yra mažesnis lyginant su būsenos vektorių metodais. *MAC* metodas yra taikomas atviro kontūro stabiliems procesams. Šis metodas naudojamas energetikos objektuose, stiklo gamybos krosnyse, garo generatoriuose, distiliavimo kolonose naftos perdirbimo gamyklose [1].

1.2.3 Prognozuojamas funkcinis valdymas

Prognozuojamo funkcinio valdymo (angl. *Predictive functional control, PFC*) pagrindiniai principai buvo sukurti 1968 metais ir pirmieji taikymai atlikti 8-ojo dešimtmečio pradžioje.

9-ojo dešimtmečio pabaigoje Richaletas išplėtojo šio metodo taikymą greitai kintantiems procesams. *PFC* gali naudoti bet kokį modelį, tačiau dėl šio metodo charakteristikų, būsenų erdvės modeliai dažniausiai yra naudojami laikui ir taikomi netiesiniams bei nestabiliems tiesiniams vidiniams modeliams.

Tačiau būsenos erdvės metodo naudojimas negali įvykdyti praktinių valdymo uždavinių reikalavimų. Gauti tikslų matematinį modelį yra labai sudėtinga, ypač netiesiniams su vėlinimu ir laike kintantiems procesams.

Sutampantys taškai ir bazinė funkcija yra pagrindinės *PFC* charakteristikos. Sutampantis taškas yra naudojamas palengvinti skaičiavimą atsižvelgiant tik į taškų poaibį prognozuojamame laikotarpyje. Norimi ir prognozuojami būsimi išėjimai turi sutapti tik prognozuojamo laikotarpio taškų poaibyje, o ne visame prognozuojamame laikotarpyje [11].

Bazinės funkcijos pasirinkimas priklauso nuo proceso charakteristikų ir norimos užduotos vertės. Tai apibrėžia įėjimo profilį per visą laikotarpį naudojant mažas parametų reikšmes.

Atsižvelgiant į erdvės būsenos modelį:

$$x(t) = Ax(t-1) + Bu(t-1), \quad y(t) = Cx(t). \quad (1.10)$$

Prognozė yra gaunama pridėdant kompensaciją:

$$\dot{y}\left(t + \frac{j}{t}\right) = y(t+j) + \hat{e}\left(t + \frac{j}{t}\right). \quad (1.11)$$

Būsimas valdymo signalas yra struktūrizuotas kaip pagrindinių tiesinių funkcijų kombinacija:

$$u(t+j) = \sum_{i=1}^{N_B} \mu_i(t) B_i(j). \quad (1.12)$$

Minimizuota nuostolių funkcija yra:

$$J = \sum_{i=1}^{N_H} [\dot{y}(t + h_i) - w(t + h_i)]^2, \quad (1.13)$$

kur h_i yra bendras sutampančių taškų skaičius.

$$w(t + j) = r(t + j) - \alpha^J (r(t) - y(y)). \quad (1.14)$$

Kvadratinės formos $\lambda[\Delta u(j)]^2$ faktorius gali būti pridedamas prie nuostolių funkcijos tam, kad gauti tolydų valdymo signalą.

PFC metodo prognozuojamo modelio išėjimas susideda iš dviejų dalių: laisvojo išėjimo ir priverstinio išėjimo. Laisvasis išėjimas priklauso nuo praėjusio įėjimo ir išėjimo, bet nepriklauso nuo esamo ar būsimo įėjimo. Priverstinis išėjimas yra esamo laiko atsakas įėjimui.

Prognozuojamo modelio išėjimas yra:

$$y(t + j) = CA^j x(t) + \sum_{i=1}^{N_B} y_{B_i}(j) \mu_i(t). \quad (1.15)$$

Būsimo valdymo poveikis gali būti gautas minimizuojant kvadratų sumą tarp prognozuojamo išėjimo ir nuorodos trajektorijos sutapimo taškuose.

$$J = \sum_{i=1}^{N_H} [y_B(h_i) \mu - d(t + h_i)]^2. \quad (1.16)$$

Valdymo signalas aprašomas:

$$u(t) = \sum_{i=1}^{N_H} \mu_i(t) B_i(0). \quad (1.17)$$

Tik pirmoji valdymo signalo sekos vertė yra vykdoma. Šis algoritmas gali būti naudojamas tik stabiliems modeliams [1].

PFC metodas naudoja nuorodos trajektorijos laiko pastoviąją kaip pagrindinį reguliavimo parametą. Mažesnė laiko pastovioji reikalauja staigesnio valdymo, o didelė laiko pastovioji sąlygoja tolydesnį poveikį. Tai pagerina uždaro kontūro sistemos santykinį stabilumą, kas reiškia, kad reguliatorius gali toleruoti modelio neatitikimą.

Analitinis būdas yra naudojamas valdyti įėjimo apribojimus. Tai sąlygoja modeliavimo paklaidas prieš ir po parametrų pakeitimo ir tai tampa valdančiojo signalo taisykle, kuri egzistuoja ir kituose *MPC* methoduose. Reguliavimo paprastumas ir lengva priežiūra yra pagrindiniai *PFC* metodo privalumai [12].

Šis metodas naudojamas robotų, raketų, objekto sekimo, reaktorių ir šildytuvų, mechaninių servo pavarų taikymo procesuose bei plieno ir aliuminio pramonėje [13].

1.2.4 Išplėstinės prognozės savaimė prisitaikantis valdymas

1985 metais, De Keyseras ir Van Cauwenberghas sukūrė išplėstinės prognozės savaimė prisitaikantį valdymo metodą (angl. *Extended prediction self-adaptive control, EPSAC*). Šis metodas proceso modeliavimui naudoja diskretinę (z – transformacijos) perdavimo funkciją ir siūlo pastovų valdymo signalą, prasidedantį nuo dabartinio momento, kai naudojamas suboptimalus prognozavimas vietoj Diofantinės lygties sprendimo [14].

Prognozavimui procesas yra modeliuojamas naudojant perdavimo funkciją su trikdžiu:

$$A(z^{-1})y(t) = B(z^{-1})u(t - d) + x(t), \quad x(t) = C(z^{-1})e(t). \quad (1.18)$$

Parametro vektorius yra apskaičiuotas naudojant išplėsto mažiausių kvadratų metodo vidurkius:

$$\Delta y(t) = \Phi^T(t) \cdot \theta(t) + \eta(t). \quad (1.19)$$

Tuomet vieno žingsnio į priekį prognozė yra:

$$\Delta \hat{y}\left(t + \frac{1}{t}\right) = \hat{y}\left(t + \frac{1}{t}\right) - y(t). \quad (1.20)$$

Žingsnio j į priekį prognozei ($j = 2, 3, \dots, N$), proceso išėjimas be trikdžio yra prognozuojamas naudojant keleto žingsnių vidurkių prognozę:

$$A(z^{-1})\left[\hat{y}\left(t + \frac{j}{t}\right) - \hat{y}\left(t + j - \frac{1}{t}\right)\right] = B(z^{-1})\Delta u(t + j - d). \quad (1.21)$$

Kai yra skaičiuojamas valdymo poveikis, prognozuojamos vertės priklauso nuo pradinių sąlygų. Atsižvelgiant, kad

$$\Delta u(t + j) = 0, \quad \text{kai } j > 0,$$

valdančiojo signalo vertė yra gaunama minimizuoti nuostolių funkciją:

$$J = \sum_{j=d}^N \delta(j) [w(t + j) - P(z^{-1})\hat{y}\left(t + \frac{j}{t}\right)]^2. \quad (1.22)$$

Valdymo taisyklė, kuri minimizuoja nuostolius yra:

$$u(t) = \frac{\sum_{j=d}^N h_j \delta(j) [w(t + j) - P(z^{-1})\hat{y}\left(t + \frac{j}{t}\right)]}{\sum_{j=d}^N \delta(j) h_j^2}. \quad (1.23)$$

Tai parodo, kad valdymo taisyklės struktūra yra labai paprasta ir skaičiavimas yra sumažinamas iki vienos vertės $u(t)$ [15].

Galimi reguliavimo parametrai yra prognozės laikotarpis, svorio faktorius ir polinomo filtras. Tačiau realaus laiko prognozės laikotarpio reguliavimas turi įtakos kelių žingsnių prognozės ir valdymo struktūrai. Atviro kontūro nuliai atsiranda kaip ir uždaro kontūro nuliai. Kadangi proceso nuliai nėra panaikinami, ilgo laikotarpio prognozuojamo valdymo strategija gali būti taikoma ne minimalios fazės procesams. Pastovi užduota vertė w yra sekama be paklaidos [16].

1.2.5 Išplėstinio laikotarpio adaptyvus valdymas

1984 metais, B. E. Ydstas sukūrė išplėstinio laikotarpio adaptyvaus valdymo metodą (angl. *Extended horizon adaptive control, EHAC*), kuris naudoja parametrinį proceso modelį. Šis būdas vadinamas *EHAC*, nes jis leidžia ilgą laiką valdyti proceso išėjimą pagal norimą vertę, užuot naudojant fiksuotą vėlinimo laiką ir trumpą intervalą. *EHAC* vadovaujasi keleto žingsnių strategija, kai galutinis išėjimas priklauso nuo esamo įėjimo ir nuo įėjimų, kurie yra realizuojami ateityje [17].

Proceso modelis naudojant perdavimo funkciją be trikdžio yra:

$$A(z^{-1})y(t) = B(z^{-1})u(t - d). \quad (1.24)$$

Pagrindinė *EHAC* idėja yra skaičiuoti įėjimų seką kiekvienų laiko momentu $[u(t), u(t+1), \dots, u(t + N - d)]$, kad minimizuoti neatitikimus tarp modelio ir momentinės užduotos vertės $(t + N)$:

$$\dot{y}\left(t + \frac{N}{t}\right) - w(t + N) = 0, \quad \text{kai } N \geq d. \quad (1.25)$$

Kita strategija yra taikyti pastovų valdymą $u(t) = u(t + 1) = \dots = u(t + N - d)$, per intervalą $[t, t + N - d]$ arba minimizuoti valdymo bandymus, t.y. apskaičiuoti $u(t) \dots u(t + N - d)$, kad minimizuoti nuostolį:

$$J = \sum_{j=0}^{N-d} u^2(t + j), \quad \text{kai } N \geq d. \quad (1.26)$$

Nuostolių funkcija, kuri susitvarko su trikdžiais yra:

$$J = \sum_{j=0}^{N-d} \Delta u^2(t + j), \quad (1.27)$$

kur $\Delta u(t + j) = u(t + j) - u(t + j - 1)$.

Didėjantis N žingsnis sekančiai prognozei yra:

$$\dot{y}\left(t + \frac{N}{t}\right) = y(t) + F(z^{-1})\Delta y(t) + E(z^{-1})B(z^{-1})\Delta u(t + N - d). \quad (1.28)$$

Pirmasis valdančiojo signalo elementas, kuris minimizuoja nuostolių rodiklį (1.27) yra:

$$u(t) = u(t - 1) + \frac{\alpha_0(w(t + N) - \dot{y}\left(t + \frac{N}{t}\right))}{\sum_{j=0}^{N-d} \alpha_j^2}, \quad (1.29)$$

α_j yra koeficientas prognozės lygtyje $\Delta u(t + j)$.

Taigi, valdymo taisyklė, kuri priklauso tik nuo proceso parametrų ir tik nuo reguliuojamo parametro *EHAC* metode, yra prognozuojamas laikotarpis N . *EHAC* metode, tik vienu laiko momentu ateityje nuokrypis yra priimamas įvertinimui, todėl ši metodą yra lengva

realizuoti. Pasirinkus tinkamą prognozavimo laikotarpį, tam tikros ne minimizavimo sistemos gali būti stabilizuotos.

Tačiau, kai $\alpha_0 = 0$ joks valdymas nėra galimas. Tam tikri dažniai negali būti eliminuoti, nes neįmanoma numatyti valdymo bandymų kiekviename taške ir valdymo laikotarpio prailginimas sąlygoja lėtesnį valdymą.

1986 metais, *EHAC* metodas buvo išplėstas kelių kintamųjų atviro kontūro sistemų naudojimui. Algoritmas nereikalauja žinių apie sistemoje veikiančią matricą ir jis toleruoja išėjimo trikdžių efektą. Tačiau kelių kintamųjų reguliatoriai, pagrįsti pagal vieno žingsnio priekyje kriterijų yra jautrūs vėlinimo struktūros parinkimui. Cikliška elgsena yra išvengiama naudojant besikeičiančio laikotarpio valdymą [1].

1.2.6 Apibendrintas prognozuojantis valdymas

Apibendrintas prognozuojantis valdymas (angl. *Generalized predictive control, GPC*) yra vienas populiariausių prognozuojamo valdymo algoritmų, kurį sukūrė D. W. Clarkas 1987 metais.

GPC metodas išlaiko *GMV/PP* technikos lankstumą ir efektyvumą. Šis metodas pradėjo naudoti integruoto valdomo autoregresijos slenkančio vidurkio (angl. *Integrated controlled auto regressive moving average, CARIMA*) modelį. Pagrindinis skirtumas tarp *GPC* ir *DMC* metodo yra modelio panaudojimas apibūdinti objektą ir dinaminės matricos formulavimą [3].

Valdymo tikslų tenkinimas paskatino platų *CARIMA* modelio naudojimą. Šis modelis dažniausiai taikomas pramonėje, kur trikdžiai yra nepastovūs. *CARIMA* modelis naudojamas gauti geras išėjimo prognozes ir optimizuoti būsimų valdančiųjų signalų seką, kad minimizuoti daugiapakopę nuostolių funkciją. Trikdžio įtraukimas yra būtinas norint sudaryti tinkamą reguliatoriaus struktūrą [18].

$$A(z^{-1})y(t) = B(z^{-1})u(t-1) + C(z^{-1})\frac{e(t)}{\Delta}. \quad (1.30)$$

GPC metodas tinkamas ne minimalios fazės, atviro kontūro nestabiliam ir turinčiam kintamuosius, kurie turi kritinius nukrypimus nuo darbo taško, taikymui. Šis metodas gali atsižvelgti į pastovias ir besikeičiančias būsimas užduotas reikšmes.

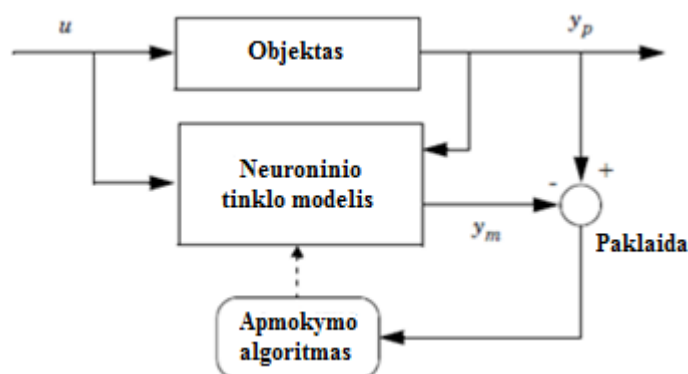
GPC metodas parodo gerus rezultatus cemento gamyboje, sausintuvų bokštuose ir robotų rankų valdyje [19].

1.3 Neuroninio tinklo modeliu prognozuojamas valdymas

Neuroninio tinklo modeliu prognozuojamas reguliatorius, kuris realizuojamas pasitelkiant neuroninio tinklo įrankį (angl. *Neural Network Toolbox*), naudoja netiesinio objekto neuroninį tinklo modelį, kad numatyti būsimą objekto charakteristiką. Regulatorius skaičiuoja valdantįjį įėjimą, kuris optimizuoja objekto charakteristiką per nustatytą laikotarpį. Pirmasis žingsnis naudojantis modeliu prognozuojamu valdymu yra nustatyti neuroninio tinklo objekto modelį – sistemos identifikavimas. Toliau objekto modelis naudojamas reguliatoriui numatyti būsimą objekto charakteristiką [20].

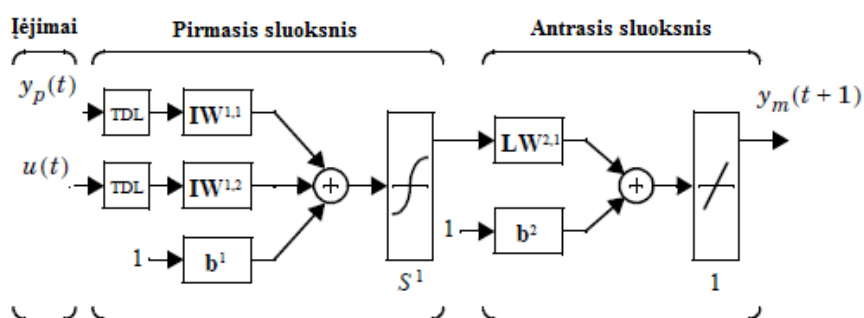
1.3.1 Sistemos identifikavimas

Pirmasis modeliu prognozuojamo valdymo etapas yra apmokėti neuroninį tinklą, kuris tinkamai atvaizduotų būsimą objekto dinamiką. Prognozuojama paklaida tarp objekto išėjimo ir neuroninio tinklo išėjimo yra naudojama neuroninio tinklo mokymo signalui. Procesas atvaizduotas 1.2 paveiksle [21].



1.2 pav. Objekto neuroninio tinklo modelio schema

Neuroninio tinklo objekto modelis naudoja ankstesnius įėjimus ir išėjimus, kad numatyti būsimas objekto išėjimo reikšmes. Objekto neuroninio tinklo modelio struktūra pateikiama 1.3 paveiksle [22].



1.3 pav. Objekto neuroninio tinklo modelio struktūra

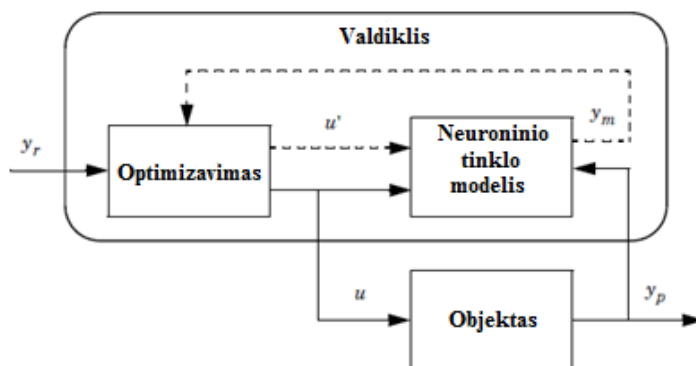
1.3.2 Prognozuojamas valdymas

Modeliu prognozuojamas valdymo metodas remiasi besikeičiančios srities technika *SoHa96*. Neuroninio tinklo modelis prognozuoja objekto atsaką per nustatytą laikotarpį. Prognozės naudoja skaitmeninę optimizavimo programą nustatyti valdantįjį signalą, kad minimizuoti atlikimo charakteristikos kriterijų J nustatytam laikotarpiui. Kriterijus J aprašomas sekančiai:

$$J = \sum_{j=N_1}^{N_2} (y_r(t+j) - y_m(t+j))^2 + \rho \sum_{j=1}^{N_u} (u'(t+j-1) - u'(t+j-2))^2. \quad (1.31)$$

kur N_1 , N_2 ir N_u apibrėžia laikotarpius, per kuriuos yra vertinama sekimo paklaida ir valdymo padidėjimas. Kintamasis u' yra bandomasis valdymo signalas, y_r yra norimas atsakas ir y_m yra tinklo modelio atsakas. Reikšmė ρ apibrėžia valdymo padidėjimų kvadratų sumos efektyvumo rodiklį [21].

1.4 paveiksle pateikiama blokinė diagrama iliustruoja modeliu prognozuojamo valdymo procesą. Reguliatorius susideda iš neuroninio tinklo objekto modelio ir optimizavimo bloko. Optimizavimo blokas apibrėžia u' reikšmes, kurios minimizuoja J kriterijų ir tuomet optimalus u yra objekto įėjimas [20].

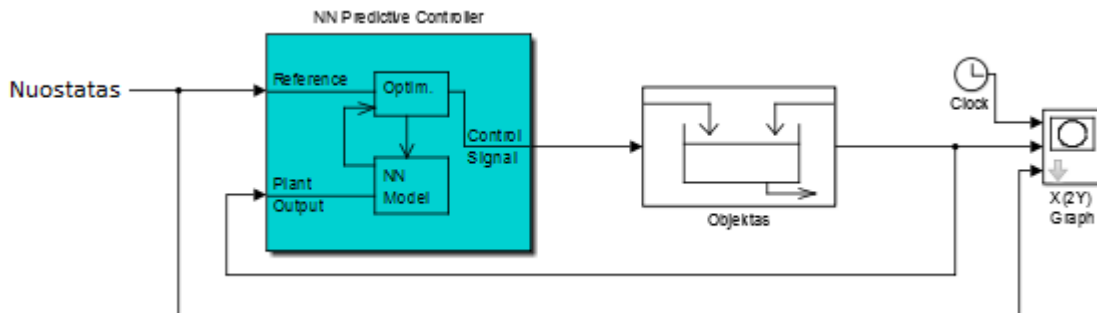


1.4 pav. Modeliu prognozuojamo valdymo proceso blokinė schema

2. PIRMINIS MPC ALGORITMŲ TAIKYMAS NESUDĖTINGŲ TIPINIŲ PROCESŲ VALDYMUI

2.1 Objekto modelis – Pirmosios eilės perdavimo funkcija su vėlavimu

Modeliu prognozuojamo valdymo algoritmų taikymui naudojamas MATLAB programos pakete esantis *NN Predictive Control* įrankis. Tipinė *NN Predictive Control* įrankio schema pateikiama 2.1 paveiksle.



2.1 pav. Tipinė *NN Predictive Control* schema

Tiriant algoritmus būtina turėti valdymo objektą. Šiame darbe, kaip valdymo objektai yra naudojami paprasti procesai, kurios galima aprašyti nesudėtingomis tipinėmis proceso modeliavimo funkcijomis. Šis objektas yra naudojamas sukurti dirbtinio neuroninio tinklo modelį, kuris po to taikomas modelio prognozuojamo valdymo algoritmuose. *NN Predictive Control* aplinkoje objekto bloke įkeliamas norimas tipinis proceso modelis, kuris reprezentuoja valdomą procesą. Identifikavimo procedūros metu, naudojant šį objektą suformuojami įėjimo ir išėjimo duomenys, kurie naudojami dirbtinio neuroninio tinklo apmokymui/neuroninio tinklo svorių identifikavimui. Taip gautas proceso modelis toliau panaudojamas modeliu prognozuojamo valdymo algoritmų formavimui. Šiuo atveju naudojamas objekto modelis yra pirmosios eilės perdavimo funkcija su vėlavimu, kuri pateikiama 2.2 paveiksle.



2.2 pav. Objekto modelis

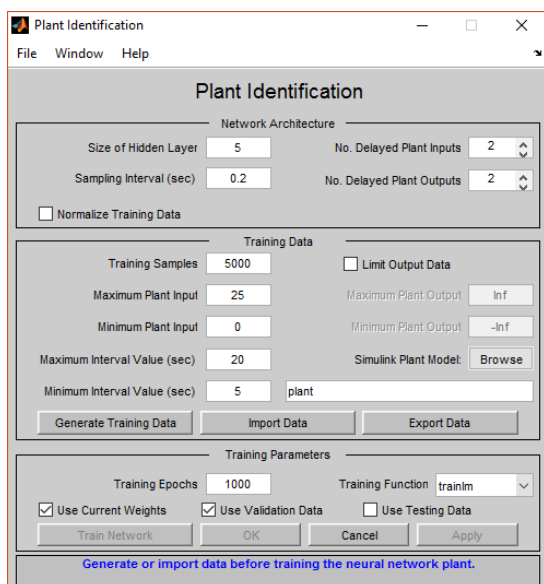
Objekto modelyje naudojamas vienas įėjimas ir vienas išėjimas. Perdavimo funkcijos (2.1) parametrai pateikiami 2.1 lentelėje.

$$\frac{K}{\tau_1 s + 1} \cdot e^{-\alpha s}. \quad (2.1)$$

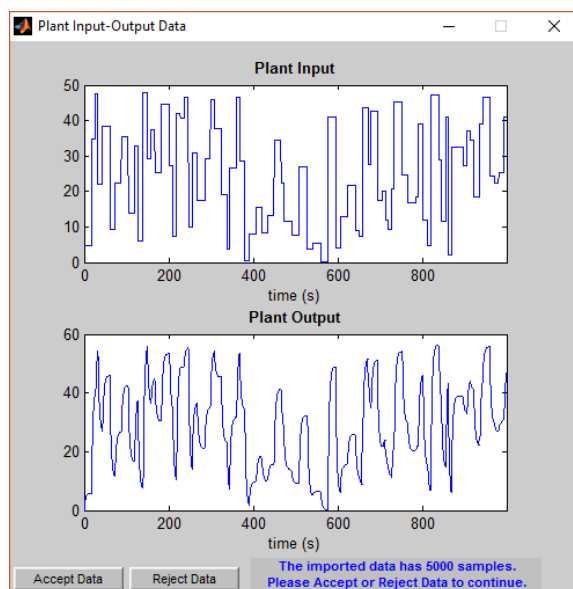
2.1 lentelė. Perdavimo funkcijos parametrai

K	1,2
τ_1	3
Vėlinimas	0,1

Šis objektas taikomas suformuoti duomenims, kurie bus naudojami dirbtinio neuroninio tinklo identifikavimui. Objekto modelio identifikavimo lange (*Plant Identification*) (2.3 pav.), pasirenkami tinklo parametrai: neuroninio tinklo paslėptų sluoksnių skaičius, pavēlintų objekto įėjimų ir išėjimų skaičius. Mokymo duomenys gali būti sugeneruojami pasirenkant norimus parametrus apmokymo duomenų (*Training Data*) skiltyje (2.4 pav.), arba gali būti įkelti jau turimi sugeneruoti mokymo duomenys. Apmokymo parametrų (*Training Parameters*) skiltyje įvedamas mokymo epochų skaičius bei iš kelių skirtingų tipų pasirenkamas mokymo funkcijos tipas.

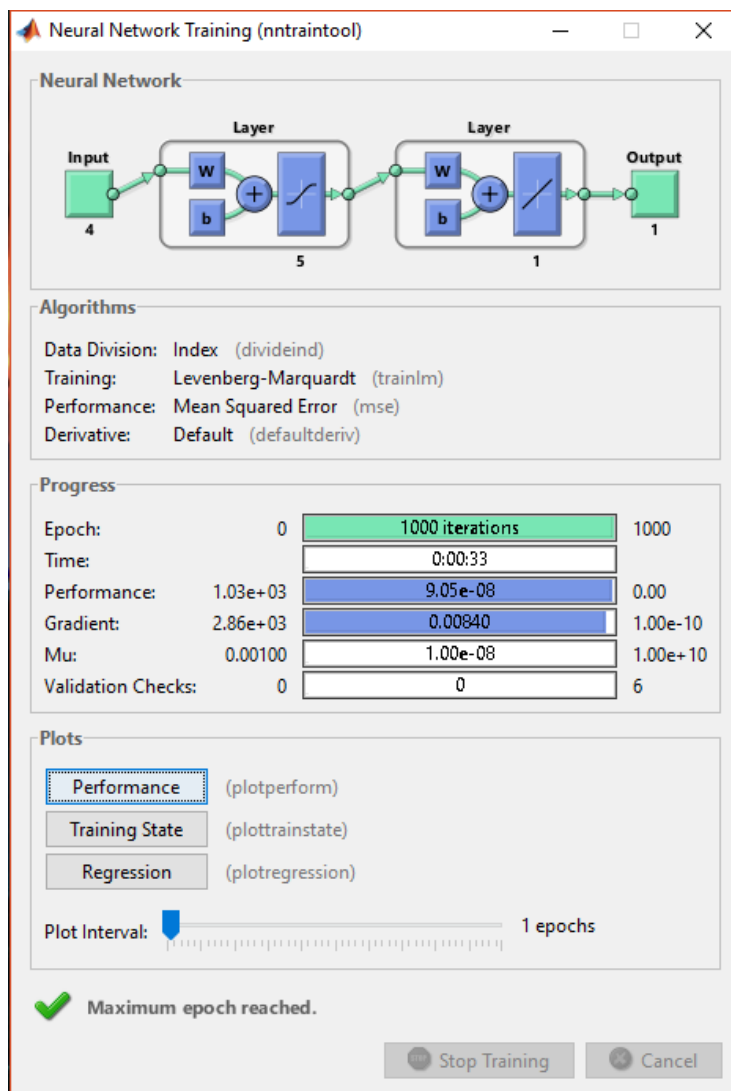


2.3 pav. Objekto modelio identifikavimo parametrų langas



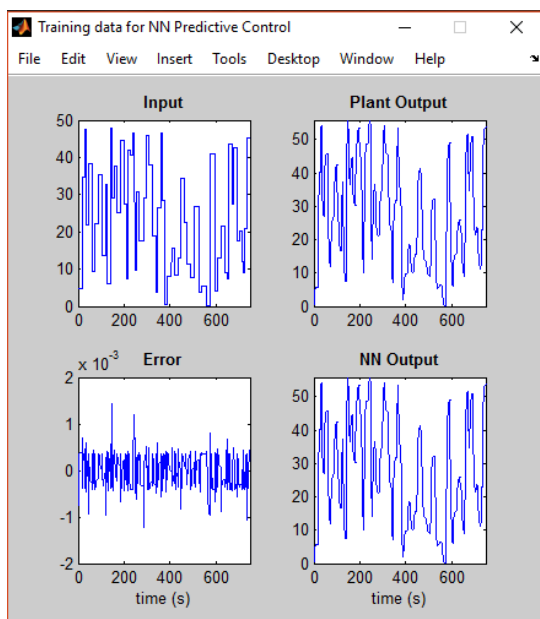
2.4 pav. Sugeneruoti mokymo duomenys

Neuroninio tinklo mokymo lange (2.5 pav.) pateikiami pagrindiniai neuroninio tinklo parametrai bei apmokymo rezultatai.

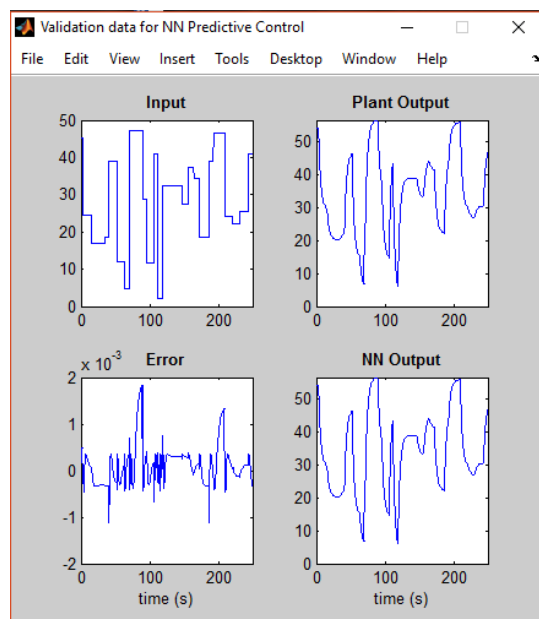


2.5 pav. Neuroninio tinklo mokymo langas

Neuroninis tinklas mokomas tol, kol pasiekiami geriausi rezultatai. Apmokant neuroninį tinklą mažėja paklaida tarp esamos ir užduotos valdymo signalo vertės. Neuroninis tinklas mokomas atsižvelgiant į mokymo ir validavimo duomenis, kurie pateikiami 2.6 ir 2.7 paveiksle. Gerai apmokytas neuroninis tinklas, turi pakankamai tiksliai atkartoti objekto išėjimą (*Plant Output*). Kai objekto ir neuroninio tinklo išėjimai sutampa bei valdymo paklaida yra maža, pradedamas objekto modeliavimas.

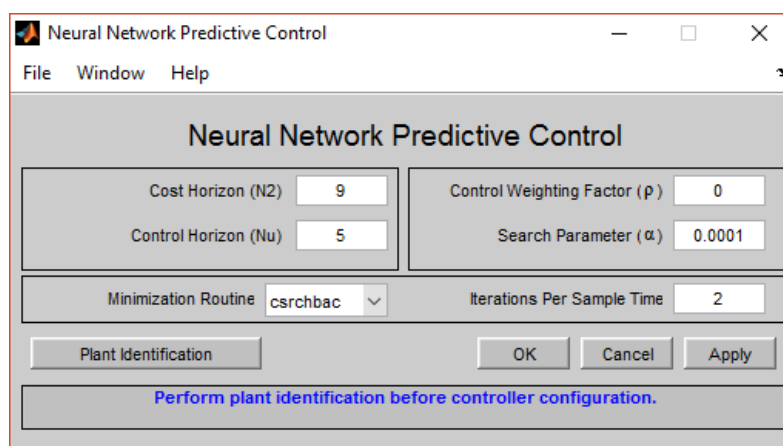


2.6 pav. Mokymo duomenys



2.7 pav. Validavimo duomenys

Neuroniniu tinklu prognozuojamo valdymo parametru langas (*Neural Network Predictive Control*) (2.8 pav.) pateikiami pagrindiniai parametrai, kuriuos keičiant reguliuojama valdymo signalo kokybė. Prognozavimo sritis (*Cost Horizon (N_2)*) – parenkama laiko sritis, kurioje modelis atlieka valdomo signalo paklaidos minimizavimą. Valdymo sritis (*Control Horizon (N_u)*) – parenkama laiko sritis, kurioje modelis atlieka valdomo signalo padidėjimo minimizavimą. Valdymo svorinis koeficientas (*Control Weighting Factor (ρ)*) – šis parametras dauginą kvadratinių valdymo padidėjimų sumą nuostolių funkcijoje. Paieškos parametras (*Search Parameter (α)*) – šis parametras apibūdina paklaidos paieškos tikslumą. Taip pat iš kelių tipų galima pasirinkti minimizuojančią funkciją algoritmo optimizavimui bei kiek iteracijų bus atlikta per laiko vienetą.



2.8 pav. Neuroniniu tinklu prognozuojamo valdymo parametru langas

Neuroniniu tinklu prognozuojamo valdymo parametrų dialogo lange (2.8 pav.) svorinio valdymo koeficiento ρ vertė prilyginama 0. Šiuo atveju, atsižvelgiant į (1.31) atlikimo funkcijos charakteristiką, reguliatorius tampa elastingesnis, nes atlikimo funkcijos vertė priklauso tik nuo prognozavimo srities N_2 . Taip proceso metu reguliatoriui leidžiama laisvai keisti valdymo srities vertę priklausomai nuo esamos užduotos vertės, todėl atitinkamai sumažinamas paieškos parametras α , taip minimizuojant tarp proceso ir užduotos reikšmės esančią paklaidos vertę.

Pasirinkus norimus neuroniniu tinklu prognozuojamo valdymo parametrus (2.8 pav.) atliekamas objekto modeliavimas ir stebima pereinamojo proceso charakteristika. Objekto modeliavimas baigiamas, kai gaunama geriausia MPC reguliatoriaus valdymo signalo kokybė, sekant nuostato vertę.

Objekto sistemos išėjimo nuokrypiui nuo užduotos nuostato vertės minimizavimui bei paklaidos skaičiavimui naudojamas kvadratinės paklaidos integralas (angl. *Integral of the Square of the Error, ISE*), kuriuo suteikiama išskirtinė didelių nuokrypių reikšmė:

$$ISE = \int_0^{\infty} e^2(t)dt \rightarrow \min . \quad (2.2)$$

Pirmosios eilės su vėlavimu perdavimo funkcijos modeliavimo rezultatai naudojant MPC reguliatorių pateikiami 2.9 paveiksle.



2.9 pav. Nesudėtingo objekto (2.1) valdymas naudojant MPC (ISE = 109)

2.2 Objekto modelis – Antrosios eilės perdavimo funkcija su vėlavimu

Šiuo atveju objekto modelyje naudojama antrosios eilės perdavimo funkcija su vėlavimu (2.10 pav.). Perdavimo funkcijos (2.3) parametrai pateikiami 2.2 lentelėje.



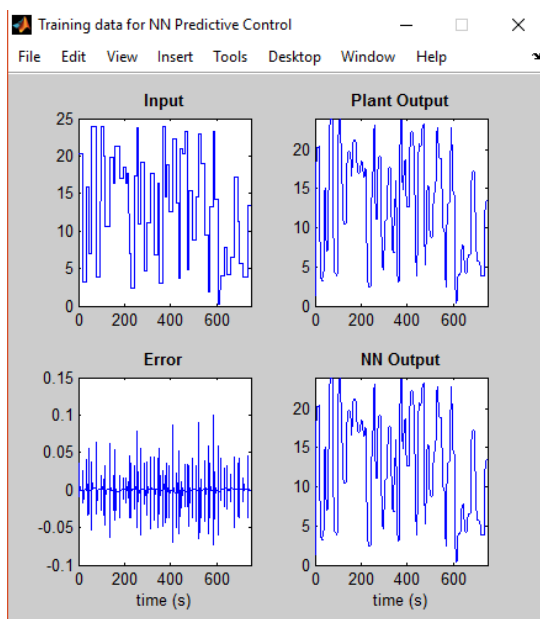
2.10 pav. Objekto modelis

$$\frac{K((\tau_1 s) + 1)}{(\tau_1 \cdot \tau_2) s^2 + (\tau_1 + \tau_2) s + 1} \cdot e^{-\alpha s}. \quad (2.3)$$

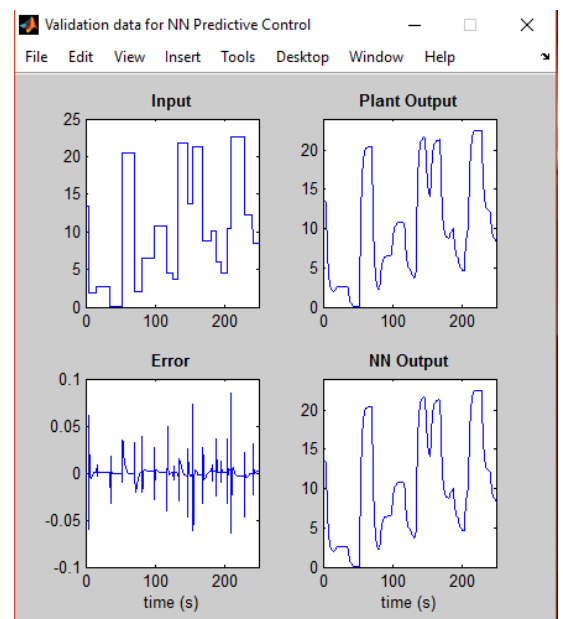
2.2 lentelė. Perdavimo funkcijos parametrai

τ_1	1
τ_2	1
K	0,5
Vėlinimas	0,15

2.11 ir 2.12 paveiksluose atitinkamai pateikiami mokymo ir validavimo duomenis. Atliekant antrosios eilės perdavimo funkcijos su vėlavimu neuroninio tinklo mokymą matyti, kad paklaida (*Error*) lyginant su pirmosios eilės perdavimo funkcijos objekto modeliu gaunama didesnė, tačiau apmokytas neuroninis tinklas tiksliai atkartoja objekto išėjimo kreivę.




2.11 pav. Mokymo duomenys



2.12 pav. Validavimo duomenys

2.13 paveiksle pateikiami antrosios eilės perdavimo funkcijos su vėlavimu objekto modeliavimo rezultatai naudojant MPC reguliatorių. Lyginant su pirmosios eilės perdavimo funkcijos objekto modeliavimo rezultatais gaunamas šiek tiek didesnis perreguliavimas, kurį sąlygoja didesnės neuroninio tinklo mokymo paklaidos, tačiau valdymo signalo kokybė nesuprastėja sekant nuostato vertę.




2.13 pav. Nesudėtingo objekto (2.3) valdymas naudojant MPC (ISE = 117)

3. MPC ALGORITMŲ TAIKYMAS NETIESINIŲ PROCESŲ VALDYMUI

3.1 Dviejų talpų modelis

Dviejų talpų sistemos schema pateikiama 3.1 paveiksle. Ši sistema susideda iš dviejų identiškų rezervuarų, kurie yra sujungti siaura anga. Šios sistemos įėjimas yra kintantis siurblio greitis, kuris keičia paduodamo skysčio srautą į pirmąjį rezervuarą. Per angą skystis teka į antrąjį rezervuarą ir iš rezervuarų. Pagrindinė valdymo užduotis yra sureguliuoti įtekantį srautą į pirmąjį rezervuarą taip, kad būtų palaikomas norimas lygis antrajame rezervuare [23].



3.1 pav. Dviejų talpų sistemos schema

Dviejų talpų proceso modelis yra netiesinė dinaminė sistema, kurios dinaminės lygtys užrašomos sekančiai:

$$\frac{dh_1}{dt} = -\frac{a_{12}}{A} \sqrt{2g|(h_1 - h_2)|} \operatorname{sgn}(h_1 - h_2) + \frac{1}{A} q; \quad (3.1)$$

$$\frac{dh_2}{dt} = \frac{a_{12}}{A} \sqrt{2g|(h_1 - h_2)|} \operatorname{sgn}(h_1 - h_2) - \frac{a_2}{A} \sqrt{2g|h_2|}, \quad (3.2)$$

čia h_1 – pirmojo rezervuaro lygis;

h_2 – antrojo rezervuaro lygis;

q_1 – įtekėjimo srautas iš pirmojo į antrąjį rezervuarą;

q_2 – ištekėjimo srautas iš antrojo rezervuaro;

q – paduodamas srautas į pirmąjį rezervuarą;

g – gravitacijos konstanta;

A – pirmojo ir antrojo rezervuaro skerspjūvio plotas;

a_2 – antrojo rezervuaro ištekėjimo angos skerspjūvio plotas;

a_{12} – angos tarp pirmojo ir antrojo rezervuaro skerspjūvio plotas.

Siurblys pumpuoti vandenį gali tik į pirmąją talpą, todėl įtekėjimo srautas visada yra teigiamas. Įtekėjimo srauto apribojimas yra:

$$q \geq 0. \quad (3.3)$$

Esant stabilioms užduotų lygių būsenoms, atitinkamos išvestinės privalo būti lygios 0:

$$\dot{h}_1 = \dot{h}_2 = 0. \quad (3.4)$$

Esant stabiliai būsenai, 3.3 ir 3.4 lygtys gali būti perrašytos sekančiai:

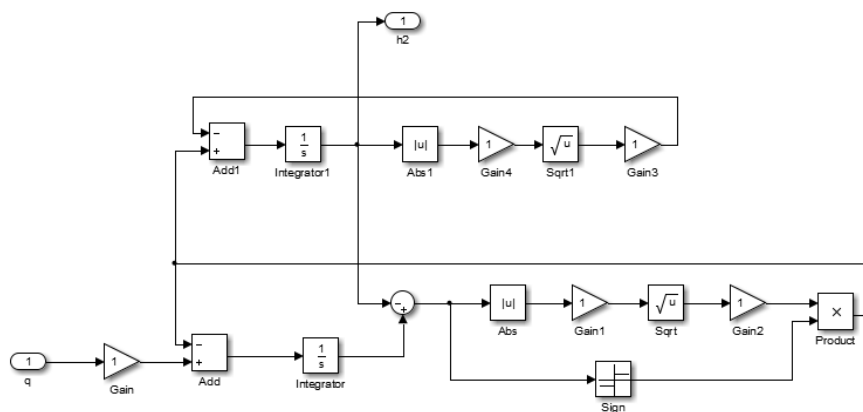
$$0 = -\frac{a_{12}}{A} \sqrt{2g|(h_1 - h_2)|} \operatorname{sgn}(h_1 - h_2) + \frac{1}{A} Q; \quad (3.5)$$

$$0 = \frac{a_{12}}{A} \sqrt{2g|(h_1 - h_2)|} \operatorname{sgn}(h_1 - h_2) - \frac{a_2}{A} \sqrt{2g|h_2|}, \quad (3.6)$$

kur Q yra stabilios būsenos įtekėjimo srautas. Iš 3.5 ir 3.6 lygčių seka, kad norint tenkinti 3.3 lygties sąlygą, taip pat turi būti tenkinama sąlyga:

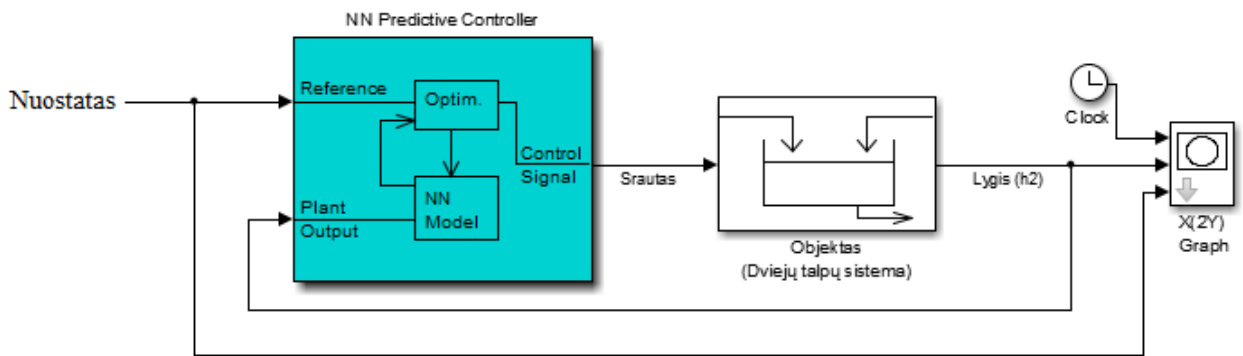
$$h_1 \geq h_2. \quad (3.7)$$

Dviejų talpų sistemos objekto modelis gali būti realizuojamas MATLAB / SIMULINK aplinkoje, kuris pateikiamas 3.2 paveiksle.



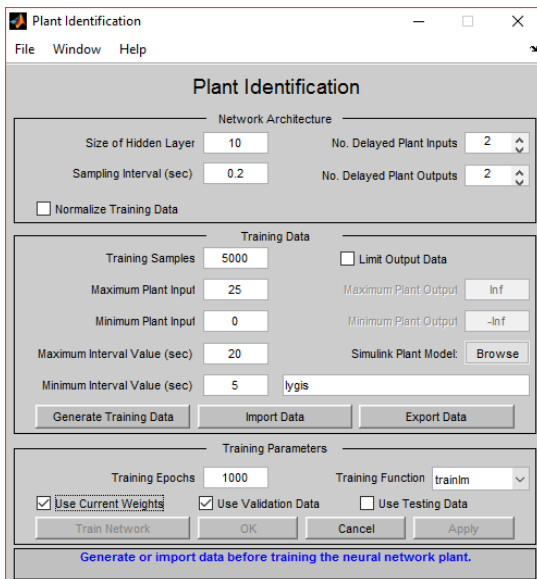
3.2 Dviejų talpų sistemos objekto modelis MATLAB / SIMULINK aplinkoje

Dviejų talpų proceso valdymo schema pateikiama 3.3 paveiksle. MPC reguliatoriaus valdymo signalas yra paduodamas srautas į pirmąjį rezervuarą, o objekto išėjimo signalas – lygis antrajame rezervuare.

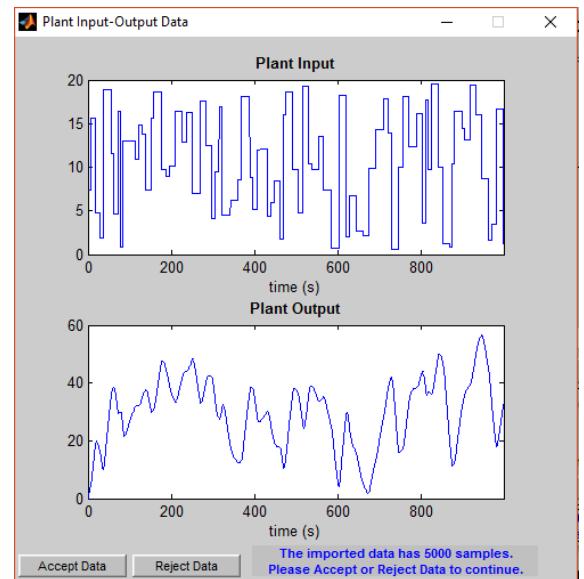


3.3 pav. Dviejų talpų proceso valdymo schema naudojant MPC SIMULINK aplinkoje

Objekto modelio identifikavimo parametų dialogo lange (3.4 pav.) pasirenkamas paslėptų sluoksnių skaičius (10) bei įkeliamas dviejų talpų sistemos objekto modelis (3.2 pav.), pagal kurį bus generuojami neuroninio tinklo mokymo duomenys. Mokymo duomenų skiltyje pasirenkamas maksimalus objekto įėjimas, o minimalus nustatomas lygus 0, kadangi paduodamas srautas į pirmąjį rezervuarą negali būti neigiamas. Sugeneruoti mokymo duomenys pateikiami 3.5 paveiksle.

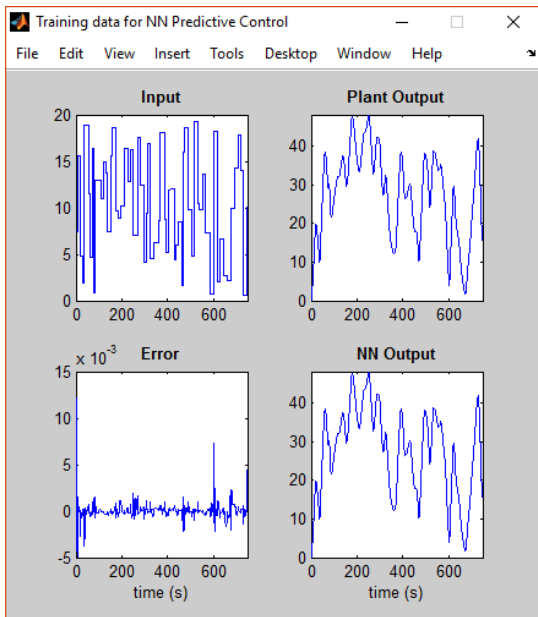


3.4 pav. Objekto modelio identifikavimo parametų langas

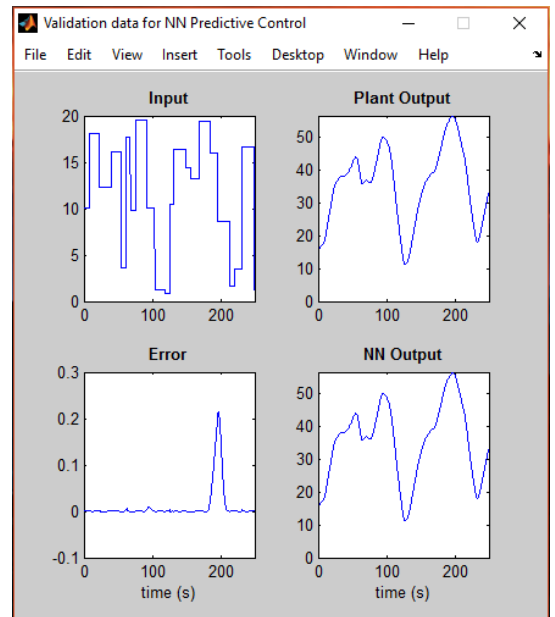


3.5 pav. Sugeneruoti mokymo duomenys

Atlikus neuroninio tinklo mokymą, gauti mokymo bei validavimo duomenys pateikiami 3.6 ir 3.7 paveiksluose. Mokymo paklaida yra maža, o apmokytas neuroninis tinklas tiksliai atkartoja dviejų talpų sistemos objekto išėjimo kreivę – lygį antrajame rezervuare.




3.6 pav. Mokymo duomenys



3.7 pav. Validavimo duomenys

Dviejų talpų proceso modeliavimo rezultatai naudojant MPC reguliatorių pateikiami 3.7 paveiksle. Grafike matyti minimalūs pereinamojo proceso perreguliavimai ir tinkama valdymo signalo kokybės charakteristika sekant nuostato vertę.



3.7 Dviejų talpų proceso modeliavimo rezultatai naudojant MPC (ISE = 3627)

4. MPC REZULTATŲ/VALDYMO KOKYBĖS PALYGINIMAS SU KLASIKINIAIS PID REGULIATORIAIS

4.1 Pirmosios eilės perdavimo funkcija su vėlavimu

4.1.1 MPC ir PID reguliatoriaus rezultatų/valdymo kokybės palyginimas (derinimas trikdžio atžvilgiu)

Dauguma reguliatorių derinimo metodų remiasi prielaida, kad valdomojo proceso dinamika gali būti apskaičiuojama pirmosios eilės perdavimo funkcija su vėlavimu:

$$W_{pr}(s) = \frac{K_{pr}}{T_{pr}s + 1} \cdot e^{-\tau_{pr}s}, \quad (4.1)$$

čia: K_{pr} – proceso stiprinimo (perdavimo) koeficientas, T_{pr} – atstojamoji laiko pastovioji, τ_{pr} – atstojamoji vėlavimo trukmė, s – Laplaso operatorius.

Pirmosios eilės perdavimo funkcijos su vėlavimu (4.2) parametrai randami iš (4.1) sąlygos:

$$W(s) = \frac{1,2}{3s + 1} \cdot e^{-0,1s}, \quad (4.2)$$

kur $K_{pr} = 1,2$, $T_{pr} = 3$, $\tau_{pr} = 0,1$.

Kadangi MPC reguliatoriaus kriterijus J (1.31) yra skirtas kvadratinės paklaidos integralui minimizuoti, todėl PID reguliatoriaus parametrai apskaičiuojami taikant ISE kriterijaus derinimo formules kompensuoti trikdančiajam poveikiui.

PID reguliatoriaus stiprinimo koeficientas:

$$K_r = \frac{1,495}{K_{pr}} \left(\frac{T_{pr}}{\tau_{pr}} \right)^{0,945} = \frac{1,495}{1,2} \left(\frac{3}{0,1} \right)^{0,945} = 30,998. \quad (4.3)$$

PID reguliatoriaus integruojanti laiko pastovioji:

$$T_i = \frac{T_{pr}}{1,101} \left(\frac{\tau_{pr}}{T_{pr}} \right)^{0,771} = \frac{3}{1,101} \left(\frac{0,1}{3} \right)^{0,771} = 0,198. \quad (4.4)$$

PID reguliatoriaus diferencijuojanti laiko pastovioji:

$$T_d = 0,560 \cdot T_{pr} \left(\frac{\tau_{pr}}{T_{pr}} \right)^{1,006} = 0,560 \cdot 3 \left(\frac{0,1}{3} \right)^{1,006} = 0,055. \quad (4.5)$$

PID reguliatoriaus parametrai perskaičiuojami, kad juos būtų galima naudoti MATLAB / SIMULINK aplinkoje.

PID reguliatoriaus P dedamoji:

$$P = K_r = 30,998 . \quad (4.6)$$

PID reguliatoriaus I dedamoji:

$$I = \frac{K_r}{T_i} = \frac{30,998}{0,198} = 161,46 . \quad (4.7)$$

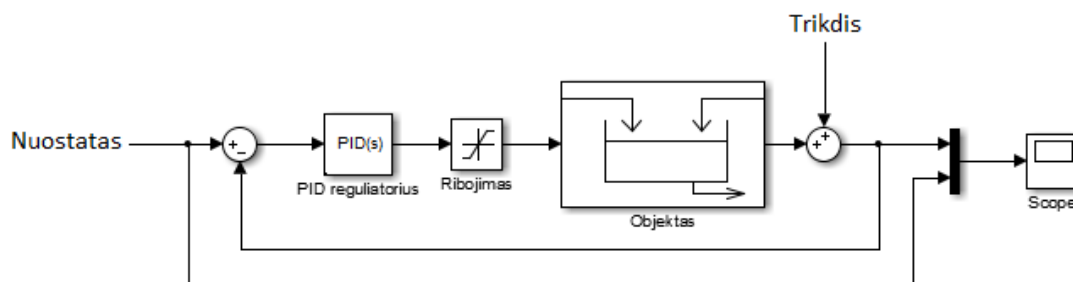
PID reguliatoriaus D dedamoji:

$$D = K_r \cdot T_d = 30,998 \cdot 0,055 = 1,705 . \quad (4.8)$$

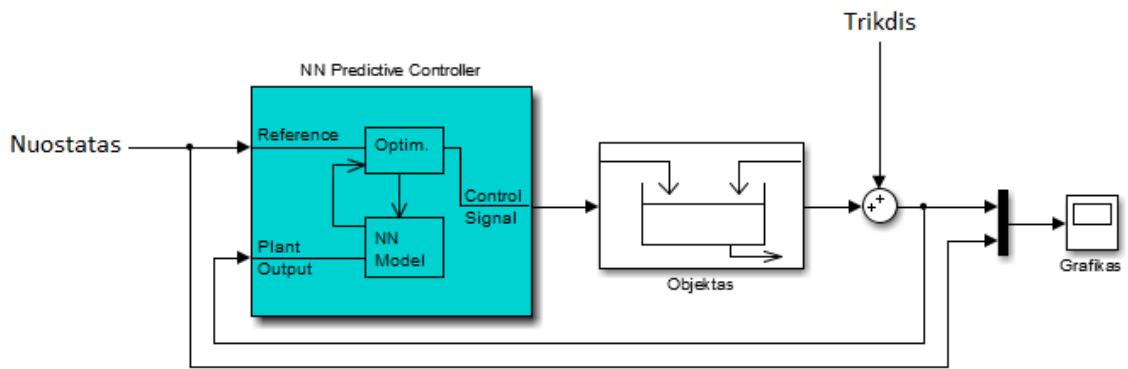
Apskaičiuavus PID reguliatoriaus parametrus, sudaromas objekto modelis, kuris pateikiamas 4.1 paveiksle. Įtraukiamas PID reguliatorius su apskaičiuotais parametrais bei reguliatoriaus išėjimą ribojantis blokas, kuris apriboja didžiules valdančiojo signalo vertes dėl reguliatoriuje esančios D dedamosios. Ribos nustatomos pagal MPC reguliatoriaus valdančiojo signalo vertes, kad būtų galima palyginti realiomis sąlygomis gaunamus abiejų reguliatorių valdymo kokybės rezultatus.

Atliekant pirmosios eilės perdavimo funkcijos su vėlavimu objekto derinimą trikdžio atžvilgiu, pasikeitus nuostato vertei ir nusistovėjus pereinamajam procesui įvedamas šuoliškas impulsas – trikdys. Stebima proceso charakteristika ir kaip į trikdį sureagoja reguliatorius vėl grąžinant proceso vertę ties nuostato reikšme.

Objekto modelio schemas taikant PID ir MPC reguliatorius atitinkamai pateikiamos 4.1 ir 4.2 paveiksluose.




4.1 pav. Objekto valdymo schema taikant PID reguliatorių




4.2 pav. Objekto valdymo schema taikant MPC reguliatorių

PID reguliatoriaus modeliavimo rezultatai pirmosios eilės perdavimo funkcijai su vėlavimu, keičiant nuostatą ir įvedus trikdį pateikiami 4.3 paveiksle ir 4.1 lentelėje.




4.3 pav. Modeliavimo rezultatai taikant PID reguliatorių suderintą trikdžio atžvilgiu (ISE = 188)

4.4 paveiksle ir 4.1 lentelėje pateikiami MPC reguliatoriaus modeliavimo rezultatai, keičiant nuostatą ir įvedus trikdį prie tų pačių reikšmių.




4.4 pav. Modeliavimo rezultatai taikant MPC reguliatorių (ISE = 164)

PID ir MPC reguliatorių paklaidos grafikai atitinkamai pateikiami 4.5 ir 4.6 paveiksluose.




4.5 pav. PID reguliatoriaus paklaidos grafikas




4.6 pav. MPC regulatoriaus paklaidos grafikas

PID ir MPC regulatorių valdančiojo signalo grafikai atitinkamai pateikiami 4.7 ir 4.8 paveiksluose.



4.7 pav. PID regulatoriaus valdančiojo signalo grafikas

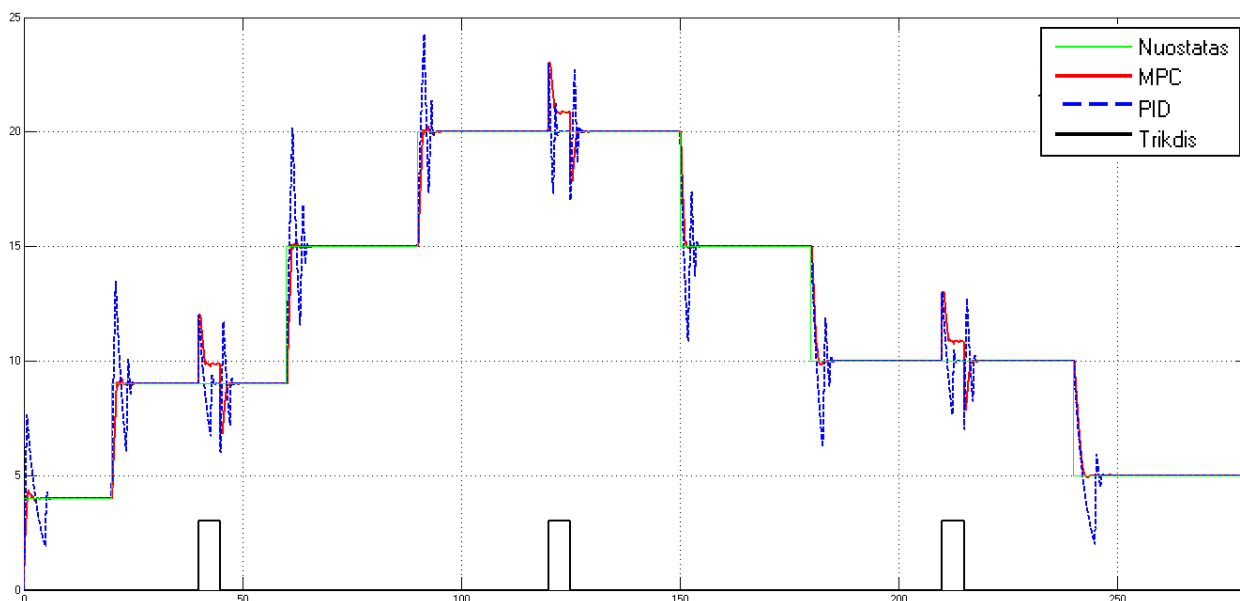


4.8 pav. MPC reguliatoriaus valdančiojo signalo grafikas

4.1 lentelėje pateikiami PID ir MPC reguliatorių valdymo kokybės pagal ISE kriterijų rezultatai. Šiuo atveju, kai objekto modelis yra pirmosios eilės perdavimo funkcija su vėlavimu, naudojant MPC reguliatorių gauti 13 % geresni ISE kriterijaus kokybės rodikliai, tačiau 4.9 paveiksle, kur bendrame grafike pateikiami PID ir MPC reguliatorių modeliavimo rezultatai matyti, kad nusistovėjimo trukmė yra panaši. Naudojant PID reguliatorių gaunamas didelis perreguliavimas dėl ISE kriterijaus charakteristikos bei derinimo formulų savybių.

4.1 lentelė. ISE kokybės kriterijaus rezultatai

Regulatorius	ISE kokybės kriterijaus vertė
PID	188
MPC	164



4.9 pav. PID ir MPC reguliatorių modeliavimo rezultatai

4.1.2 MPC ir PID reguliatoriaus rezultatų/valdymo kokybės palyginimas (derinimas nuostato atžvilgiu)

Automatinio reguliavimo sistemos, kurios yra suderintos kompensuoti trikdančiajam poveikiui, paprastai turi didesnę perreguliaciją, negu sistemos, kurios yra suderintos nuostato reikšmės sekimui.

Nuostato sekimas procesu valdymui yra ne toks svarbus, kaip trikdančiojo poveikio mažinimas. Tačiau atskiroms automatinio reguliavimo sistemoms yra keliamas reikalavimas kuo tiksliau sekti nuostato reikšmės kitimą.

MPC reguliatorius yra skirtas kvadratinės paklaidos integralui minimizuoti, tačiau ISE kriterijui nepateikiamos reguliatorių derinimo formulės nuostato atžvilgiu. Kadangi ISE kriterijaus charakteristikos yra labai panašios ir artimos absoliutinės paklaidos integralui (angl. *Integral of the Absolute value of the Error, IAE*), todėl nuostato sekimui taikomos IAE kriterijaus (4.9) derinimo formulės.

$$IAE = \int_0^{\infty} |e(t)| dt \rightarrow \min. \quad (4.9)$$

Apskaičiuojami PID reguliatoriaus parametrai taikant IAE kriterijaus derinimo formules.

PID reguliatoriaus stiprinimo koeficientas:

$$K_r = \frac{1,086}{K_{pr}} \left(\frac{T_{pr}}{\tau_{pr}} \right)^{0,869} = \frac{1,086}{1,2} \left(\frac{3}{0,1} \right)^{0,945} = 17,389. \quad (4.10)$$

PID reguliatoriaus integruojanti laiko pastovioji:

$$T_i = \frac{T_{pr}}{\left[0,74 - 0,13 \left(\frac{\tau_{pr}}{T_{pr}} \right) \right]} = \frac{3}{\left[0,74 - 0,13 \left(\frac{0,1}{3} \right) \right]} = 4,078. \quad (4.11)$$

PID reguliatoriaus diferencijuojanti laiko pastovioji:

$$T_d = 0,348 \cdot T_{pr} \left(\frac{\tau_{pr}}{T_{pr}} \right)^{0,914} = 0,348 \cdot 3 \left(\frac{0,1}{3} \right)^{0,914} = 0,0466. \quad (4.12)$$

PID reguliatoriaus parametrai perskaičiuojami, kad juos būtų galima naudoti MATLAB / SIMULINK aplinkoje.

PID reguliatoriaus P dedamoji:

$$P = K_r = 17,389 . \quad (4.13)$$


PID reguliatoriaus I dedamoji:

$$I = \frac{K_r}{T_i} = \frac{17,389}{4,078} = 4,264 . \quad (4.14)$$

PID reguliatoriaus D dedamoji:


$$D = K_r \cdot T_d = 17,389 \cdot 0,0466 = 0,8107 . \quad (4.15)$$

Apskaičiuavus PID reguliatoriaus parametrus, atliekamas pirmosios eilės perdavimo funkcijos su vėlavimu modeliavimas prie tų pačių nuostato keitimo bei trikdžio verčių. PID reguliatoriaus modeliavimo rezultatai pateikiami 4.10 paveiksle ir 4.2 lentelėje.




4.10 Modeliavimo rezultatai taikant PID reguliatorių suderintą nuostato atžvilgiu (IAE = 87)

4.11 ir 4.12 paveiksluose atitinkamai pateikiami PID reguliatoriaus paklaidos bei valdančiojo signalo grafikai.



4.11 pav. PID reguliatoriaus paklaidos grafikas




4.12 pav. PID reguliatoriaus valdančiojo signalo grafikas

4.2 lentelėje pateikiami PID ir MPC reguliatorių valdymo kokybės rezultatai taikant IAE kriterijų nuostato atžvilgiu. Šiuo atveju, PID reguliatoriaus IAE kriterijaus kokybės rodiklis yra 47 % geresnis už MPC reguliatoriaus, tačiau kadangi MPC reguliatorius yra skirtas ISE kriterijaus minimizavimui, šie rezultatai yra labiau rekomendacinio tipo lyginant MPC ir PID reguliatorių valdymo kokybę nuostato kitimo atžvilgiu.

4.2 lentelė. IAE kokybės kriterijaus rezultatai

Regulatorius	IAE kokybės kriterijaus vertė
PID	87
MPC	164



4.13 pav. PID ir MPC reguliatorių modeliavimo rezultatai


4.2 Antrosios eilės perdavimo funkcija su vėlavimu

4.2.1 Antrosios eilės su vėlavimu perdavimo funkcijos parametru identifikavimas iš šuolinės reakcijos kreivės


Praktikoje pasitaiko atveju, kai yra žinomas aukštesniosios eilės proceso modelis, kuriuo remiantis įvertinami proceso dinamiką aproksimuojamo pirmosios eilės su vėlavimu modelio parametrai, kadangi šie parametrai reikalingi PID reguliatoriaus derinimui. Tiesioginis būdas yra sumodeliuoti aukštesniosios eilės modelio reakciją į šuolinį įėjimo pokytį ir apskaičiuoti reakcijos kreivę aproksimuojančio pirmosios eilės su vėlavimu modelio parametrus.

Kai atliekami šuolinės reakcijos eksperimentai reikia įvertinti, kad perdavimo funkcijos (4.1) parametru K_{pr} , T_{pr} , τ_{pr} nustatymo tikslumas tiesiogiai priklauso nuo eksperimentinių duomenų tikslumo. Turint proceso šuolinę reakcijos kreivę, perdavimo funkcijos (4.1) parametrai gali būti nustatomi grafiniais, momentų plotų ir skaitmeniniais metodais. Momentų plotų ir skaitmeniniai metodai taikomi automatinio derinimo procedūrose, o grafiniai metodai naudojami rankiniam derinimui.

Grafiniais metodais perdavimo funkcijos parametrai nustatomi, remiantis eksperimentine reakcijos kreive. Eksperimentas reakcijos kreivei nustatyti atliekamas, atjungus sistemos reguliatorių (4.14 pav.). Iš pradžių, įvedama įėjimo dydžio vertė, ties kuria norima suderinti PID reguliatorių. Procesui nusistovėjus ir šuoliškai pakeitus proceso įėjimą dydžių Δu , fiksuojama išėjimo dydžio vertė laikui bėgant $y(t)$ tol, kol pasiekiami stabilioji vertė $y(\infty)$ (4.15 pav.) [24].



4.14 pav. Schema šuolinės reakcijos kreivei gauti



4.15 pav. Šuolinė proceso modelio reakcijos kreivė

Reakcijos kreivėje išmatuojami dydžiai pateikiami 4.16 paveiksle. Apskaičiuojami perdavimo funkcijos parametrai:


Stiprinimo koeficientas:

$$K_{pr} = \frac{y(\infty)}{\Delta u} = \frac{1}{1} = 1. \quad (4.16)$$

Kai procese dominuoja pirmosios eilės dinamika, atstojamoji laiko pastovioji:

$$T_{pr} = T_2 - \tau_{pr} = 2,15 - 0,15 = 2, \quad (4.17)$$

čia parametras T_2 nustatomas naudojant liestinę, kuri nubrėžta per reakcijos kreivės persilenkimo tašką ir sankirtą su tiese, kuri atitinka stabiliąją išėjimo vertę, o τ_{pr} – sankirta su tiese, kuri atitinka pradinę išėjimo vertę.



4.16 pav. Šuolinės proceso modelio reakcijos kreivės parametrai

4.2.2 MPC ir PID reguliatoriaus rezultatų/valdymo kokybės palyginimas (derinimas trikdžio atžvilgiu)

Antrosios eilės perdavimo funkcijos su vėlavimu (4.18) PID reguliatoriaus parametrams apskaičiuoti taip pat taikomos ISE kriterijaus derinimo formulės.

$$W(s) = \frac{0,5s + 1}{s^2 + 2s + 1} \cdot e^{-0,15s}. \quad (4.18)$$

PID reguliatoriaus stiprinimo koeficientas:

$$K_r = \frac{1,495}{K_{pr}} \left(\frac{T_{pr}}{\tau_{pr}} \right)^{0,945} = \frac{1,495}{1} \left(\frac{2}{0,15} \right)^{0,945} = 17,29. \quad (4.19)$$

PID reguliatoriaus integruojanti laiko pastovioji:

$$T_i = \frac{T_{pr}}{1,101} \left(\frac{\tau_{pr}}{T_{pr}} \right)^{0,771} = \frac{2}{1,101} \left(\frac{0,15}{2} \right)^{0,771} = 0,247. \quad (4.20)$$

PID reguliatoriaus diferencijuojanti laiko pastovioji:

$$T_d = 0,560 \cdot T_{pr} \left(\frac{\tau_{pr}}{T_{pr}} \right)^{1,006} = 0,560 \cdot 2 \left(\frac{0,15}{2} \right)^{1,006} = 0,083 . \quad (4.21)$$

PID reguliatoriaus parametrai perskaičiuojami, kad juos būtų galima naudoti MATLAB / SIMULINK aplinkoje.

PID reguliatoriaus P dedamoji:

$$P = K_r = 17,29 . \quad (4.22)$$

PID reguliatoriaus I dedamoji:


$$I = \frac{K_r}{T_i} = \frac{17,29}{0,247} = 70 . \quad (4.23)$$

PID reguliatoriaus D dedamoji:

$$D = K_r \cdot T_d = 17,29 \cdot 0,083 = 1,435 . \quad (4.24)$$


Objekto valdymo schemeje (4.1 pav.), į objekto modelį įtraukiama antrosios eilės su vėlavimu perdavimo funkcija bei apskaičiuoti PID reguliatoriaus parametrai. MPC reguliatoriaus valdymo schemeje (4.2 pav.) analogiškai taip pat pakeičiamas ir objekto modelis.

PID reguliatoriaus modeliavimo rezultatai antrosios eilės perdavimo funkcijai su vėlavimu, keičiant nuostatą ir įvedus trikdį pateikiami 4.17 paveiksle ir 4.3 lentelėje.




4.17 pav. Modeliavimo rezultatai taikant PID reguliatorių suderintą trikdžio atžvilgiu (ISE=207)

4.18 paveiksle ir 4.3 lentelėje pateikiami MPC reguliatoriaus modeliavimo rezultatai, keičiant nuostatą ir įvedus trikdį prie tų pačių reikšmių.




4.18 pav. Modeliavimo rezultatai taikant MPC reguliatorių (ISE = 174)

PID ir MPC reguliatorių paklaidos grafikai atitinkamai pateikiami 4.19 ir 4.20 paveiksluose.




4.19 pav. PID reguliatoriaus paklaidos grafikas




4.20 pav. MPC regulatoriaus paklaidos grafikas

PID ir MPC regulatorių valdančiojo signalo grafikai atitinkamai pateikiami 4.21 ir 4.22 paveiksluose.



4.21 pav. PID regulatoriaus valdančiojo signalo grafikas




4.22 pav. MPC regulatoriaus valdančiojo signalo grafikas

4.3 lentelėje pateikiami PID ir MPC reguliatorių valdymo kokybės pagal ISE kriterijų rezultatai. Šiuo atveju, kai objekto modelis yra antrosios eilės perdavimo funkcija su vėlavimu, taikant MPC reguliatorių gauti 16 % geresni ISE kriterijaus kokybės rodikliai. 4.23 paveiksle matyti, kad PID ir MPC reguliatorių pereinamųjų procesų nusistovėjimo trukmė yra panaši.

4.3 lentelė. ISE kokybės kriterijaus rezultatai

Regulatorius	ISE kokybės kriterijaus vertė
PID	207
MPC	174



4.23 pav. PID ir MPC reguliatorių modeliavimo rezultatai

4.2.3 MPC ir PID reguliatoriaus rezultatų/valdymo kokybės palyginimas (derinimas nuostato atžvilgiu)

Antrosios eilės perdavimo funkcijos su vėlavimu PID reguliatoriaus parametrams, suderintiems nuostato atžvilgiu, taip pat taikomos IAE kriterijaus derinimo formulės.

PID reguliatoriaus stiprinimo koeficientas:

$$K_r = \frac{1,086}{K_{pr}} \left(\frac{T_{pr}}{\tau_{pr}} \right)^{0,869} = \frac{1,086}{1} \left(\frac{2}{0,15} \right)^{0,945} = 10,31. \quad (4.25)$$

PID reguliatoriaus integruojanti laiko pastovioji:

$$T_i = \frac{T_{pr}}{\left[0,74 - 0,13 \left(\frac{\tau_{pr}}{T_{pr}} \right) \right]} = \frac{2}{\left[0,74 - 0,13 \left(\frac{0,15}{2} \right) \right]} = 2,74. \quad (4.26)$$

PID reguliatoriaus diferencijuojanti laiko pastovioji:

$$T_d = 0,348 \cdot T_{pr} \left(\frac{\tau_{pr}}{T_{pr}} \right)^{0,914} = 0,348 \cdot 2 \left(\frac{0,15}{2} \right)^{0,914} = 0,065. \quad (4.27)$$

PID reguliatoriaus parametrai perskaičiuojami, kad juos būtų galima naudoti MATLAB / SIMULINK aplinkoje.

PID reguliatoriaus P dedamoji:

$$P = K_r = 10,31. \quad (4.28)$$


PID reguliatoriaus I dedamoji:

$$I = \frac{K_r}{T_i} = \frac{10,31}{2,74} = 3,763. \quad (4.29)$$

PID reguliatoriaus D dedamoji:


$$D = K_r \cdot T_d = 10,31 \cdot 0,065 = 0,67. \quad (4.30)$$

Apskaičius PID regulatoriaus parametrus, atliekamas antrosios eilės perdavimo funkcijos su vėlavimu modeliavimas. PID regulatoriaus modeliavimo rezultatai pateikiami 4.24 paveiksle ir 4.4 lentelėje.




4.24 Modeliavimo rezultatai taikant PID reguliatorių suderintą nuostato atžvilgiu (IAE = 90)

4.25 ir 4.26 paveiksluose atitinkamai pateikiami PID regulatoriaus paklaidos bei valdančiojo signalo grafikai.



4.25 pav. PID regulatoriaus paklaidos grafikas




4.26 pav. PID reguliatoriaus valdančiojo signalo grafikas

4.4 lentelėje pateikiami PID ir MPC reguliatorių valdymo kokybės rezultatai taikant IAE kriterijų nuostato atžvilgiu. Šiuo atveju, kai objekto modelis yra antrosios eilės perdavimo funkcija su vėlavimu, PID reguliatoriaus IAE kriterijaus kokybės rodiklis yra 48 % geresnis už MPC reguliatoriaus. Tačiau šie rezultatai taip pat yra labiau rekomendacinio tipo, kadangi MPC reguliatorius yra skirtas ISE kriterijaus minimizavimui.

4.4 lentelė. IAE kokybės kriterijaus rezultatai

Regulatorius	IAE kokybės kriterijaus vertė
PID	90
MPC	174



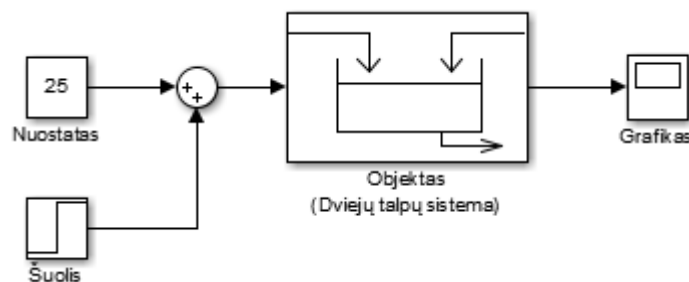
4.27 pav. PID ir MPC reguliatorių modeliavimo rezultatai

4.3 Dviejų talpų procesas


4.3.1 Dviejų talpų proceso modelio parametrų identifikavimas iš šuolinės reakcijos kreivės

Dviejų talpų proceso perdavimo funkcijos parametrai taip pat nustatomi grafiniais metodais, remiantis eksperimentine reakcijos kreive, kadangi PID reguliatorius bus derinamas pirmosios eilės su vėlavimu proceso modeliui. 4.28 paveiksle pateikiama schema šuolinei reakcijos kreivei gauti. Įkeliamas dviejų talpų proceso modelis bei nustatoma įėjimo dydžio vertė, ties kuria bus suderintas PID reguliatorius.

Šuolinė dviejų talpų proceso modelio reakcijos kreivė pateikiama 4.29 paveiksle.



4.28 pav. Šuolinės reakcijos kreivės gavimas, naudojant dviejų talpų proceso modelį



4.29 pav. Šuolinė proceso modelio reakcijos kreivė


Reakcijos kreivėje išmatuojami dydžiai pateikiami 4.30 paveiksle. Apskaičiuojami perdavimo funkcijos parametrai:

Stiprinimo koeficientas:

$$K_{pr} = \frac{y(\infty)}{\Delta u} = \frac{12,75}{1} = 12,75 . \quad (4.31)$$

Kai procese dominuoja pirmosios eilės dinamika, atstojamoji laiko pastovioji:

$$T_{pr} = T_2 - \tau_{pr} = 95 - 5 = 90 . \quad (4.32)$$



4.30 pav. Šuolinės proceso modelio reakcijos kreivės parametrai

4.3.2 MPC ir PID reguliatoriaus rezultatu/valdymo kokybės palyginimas (derinimas trikdžio atžvilgiu)

Taikant ISE kriterijaus derinimo formules apskaičiuojami PID reguliatoriaus parametrai.

PID reguliatoriaus stiprinimo koeficientas:

$$K_r = \frac{1,495}{K_{pr}} \left(\frac{T_{pr}}{\tau_{pr}} \right)^{0,945} = \frac{1,495}{12,75} \left(\frac{90}{5} \right)^{0,945} = 1,8. \quad (4.33)$$

PID reguliatoriaus integruojanti laiko pastovioji:

$$T_i = \frac{T_{pr}}{1,101} \left(\frac{\tau_{pr}}{T_{pr}} \right)^{0,771} = \frac{90}{1,101} \left(\frac{5}{90} \right)^{0,771} = 8,803. \quad (4.34)$$

PID reguliatoriaus diferencijuojanti laiko pastovioji:

$$T_d = 0,560 \cdot T_{pr} \left(\frac{\tau_{pr}}{T_{pr}} \right)^{1,006} = 0,560 \cdot 90 \left(\frac{5}{90} \right)^{1,006} = 2,752. \quad (4.35)$$

PID reguliatoriaus parametrai perskaičiuojami, kad juos būtų galima naudoti MATLAB / SIMULINK aplinkoje.

PID reguliatoriaus P dedamoji:

$$P = K_r = 1,8. \quad (4.36)$$

PID reguliatoriaus I dedamoji:


$$I = \frac{K_r}{T_i} = \frac{1,8}{8,803} = 0,205. \quad (4.37)$$

PID reguliatoriaus D dedamoji:

$$D = K_r \cdot T_d = 1,8 \cdot 2,752 = 4,954. \quad (4.38)$$


Objekto valdymo schemose (4.1 pav.) ir (4.2 pav.), į objekto modelį įtraukiamas dviejų talpų procesas bei įvedami apskaičiuoti PID reguliatoriaus parametrai.

PID reguliatoriaus modeliavimo rezultatai taikant dviejų talpų proceso modelį, keičiant nuostatą ir įvedus trikdį pateikiami 4.31 paveiksle ir 4.5 lentelėje




4.31 pav. Modeliavimo rezultatai taikant PID reguliatorių suderintą trikdžio atžvilgiu, kai keičiasi nuostatas ir įvedamas trikdys (ISE = 6934)

4.32 paveiksle ir 4.5 lentelėje pateikiami MPC reguliatoriaus modeliavimo rezultatai taikant dviejų talpų proceso modelį, keičiant nuostatą ir įvedus trikdį prie tų pačių reikšmių.




4.32 pav. Modeliavimo rezultatai taikant MPC reguliatorių, kai keičiasi nuostatas ir įvedamas trikdys (ISE = 4325)

PID ir MPC reguliatorių paklaidos grafikai atitinkamai pateikiami 4.33 ir 4.34 paveiksluose.




4.33 pav. PID reguliatoriaus paklaidos grafikas




4.34 pav. MPC reguliatoriaus paklaidos grafikas

PID ir MPC reguliatorių valdančiojo signalo grafikai atitinkamai pateikiami 4.35 ir 4.36 paveiksluose.



4.35 pav. PID reguliatoriaus valdančiojo signalo grafikas




4.36 pav. MPC reguliatoriaus valdančiojo signalo grafikas

4.5 lentelėje pateikiami PID ir MPC reguliatorių valdymo kokybės pagal ISE kriterijų rezultatai. Šiuo atveju, kai objekto modelis yra dviejų talpų procesas, naudojant MPC reguliatorių gauti 38 % geresni ISE kriterijaus kokybės rodikliai.

4.37 paveiksle pateikiami PID ir MPC reguliatorių modeliavimo rezultatai, kur matyti, kad naudojant PID reguliatorių gaunami dideli perreguliavimai bei proceso nusistovėjimo trukmė yra ilgesnė už MPC reguliatoriaus pereinamąjį procesą.

4.5 lentelė. ISE kokybės kriterijaus rezultatai

Regulatorius	ISE kokybės kriterijaus vertė
PID	6934
MPC	4325



4.37 pav. PID ir MPC reguliatorių modeliavimo rezultatai

4.3.3 MPC ir PID reguliatoriaus rezultatų/valdymo kokybės palyginimas (derinimas nuostato atžvilgiu)

Dviejų talpų proceso PID reguliatoriaus parametrus, suderintiems nuostato atžvilgiu, taip pat taikomos IAE kriterijaus derinimo formulės.

PID reguliatoriaus stiprinimo koeficientas:

$$K_r = \frac{1,086}{K_{pr}} \left(\frac{T_{pr}}{\tau_{pr}} \right)^{0,869} = \frac{1,086}{12,75} \left(\frac{90}{5} \right)^{0,945} = 1,05. \quad (4.39)$$

PID reguliatoriaus integruojanti laiko pastovioji:

$$T_i = \frac{T_{pr}}{\left[0,74 - 0,13 \left(\frac{\tau_{pr}}{T_{pr}} \right) \right]} = \frac{90}{\left[0,74 - 0,13 \left(\frac{5}{90} \right) \right]} = 122,82. \quad (4.40)$$

PID reguliatoriaus diferencijuojanti laiko pastovioji:

$$T_d = 0,348 \cdot T_{pr} \left(\frac{\tau_{pr}}{T_{pr}} \right)^{0,914} = 0,348 \cdot 90 \left(\frac{5}{90} \right)^{0,914} = 2,23. \quad (4.41)$$

PID reguliatoriaus parametrai perskaičiuojami, kad juos būtų galima naudoti MATLAB / SIMULINK aplinkoje.

PID reguliatoriaus P dedamoji:

$$P = K_r = 1,05. \quad (4.42)$$


PID reguliatoriaus I dedamoji:

$$I = \frac{K_r}{T_i} = \frac{1,05}{122,82} = 0,00814. \quad (4.43)$$

PID reguliatoriaus D dedamoji:


$$D = K_r \cdot T_d = 1,05 \cdot 2,23 = 2,3415. \quad (4.44)$$

Dviejų talpų proceso modeliavimo rezultatai naudojant PID reguliatorių su apskaičiuotais parametrais nuostato atžvilgiu pateikiami 4.38 paveiksle ir 4.6 lentelėje.




4.38 Modeliavimo rezultatai taikant PID reguliatorių suderintą nuostato atžvilgiu (IAE = 7589)

4.39 ir 4.40 paveiksluose atitinkamai pateikiami PID reguliatoriaus paklaidos bei valdančiojo signalo grafikai.



4.39 pav. PID reguliatoriaus paklaidos grafikas




4.40 pav. PID reguliatoriaus valdančiojo signalo grafikas

4.6 lentelėje pateikiami PID ir MPC reguliatorių valdymo kokybės rezultatai taikant IAE kriterijų nuostato atžvilgiu. Šiuo atveju, kai objekto modelis yra dviejų talpų procesas, MPC reguliatoriaus IAE kriterijaus kokybės rodiklis yra 43 % geresnis už PID reguliatoriaus.

4.41 paveiksle pateikiami PID ir MPC reguliatorių modeliavimo rezultatai. Naudojant PID reguliatorių pereinamojo proceso perreguliuavimą nėra, tačiau ženkliai pailgėja proceso nusistovėjimo trukmė.

4.6 lentelė. IAE kokybės kriterijaus rezultatai

Regulatorius	IAE kokybės kriterijaus vertė
PID	7589
MPC	4325



4.41 pav. PID ir MPC reguliatorių modeliavimo rezultatai

REZULTATAI IR IŠVADOS

1. Apžvelgta modelių prognozuojamo valdymo metodologija. Išanalizuota šio metodo vystymosi raida bei pagrindinės valdymo strategijos, kurios plačiausiai taikomos praktikoje;
2. Išanalizuoti pagrindiniai prognozavimo metodo veikimo principai bei pasirinkti tipiniai objektai ir jų modeliai, kurie buvo naudojami tiriant modelių prognozuojamo valdymo algoritmus;
3. Apžvelgtas neuroninių tinklų taikymas objektų modelių identifikavimui ir modelių prognozuojamame valdyme. Išanalizuoti objektų identifikavimas pasitelkiant dirbtinius neuroninius tinklus bei objekto neuroninio tinklo modelio sudarymo principai;
4. Naudojantis MATLAB/SIMULINK programos paketu, atlikti modelių prognozuojamo valdymo algoritmų taikymai nesudėtingų ir netiesinių procesų valdymui. Iš gautų rezultatų matyti, kad su tinkamai parinktais neuroniniais tinklais galima tiksliai aprašyti tiriamus objektus, gauti modeliavimo rezultatai duoda mažas modeliavimo paklaidas, o modelių prognozuojamas valdymas pasitelkiant dirbtinių neuroninių tinklų modelius pasiekė aukštus kokybės rodiklius. Valdymo signalas tinkamai atkartoją kintančią laikę užduoties vertę be žymesnių perreguliuojimų ir su minimalia paklaida;
5. Atlikus MPC ir PID reguliatorių rezultatų/valdymo kokybės palyginimą, kai objekto modelis yra pirmosios bei antrosios eilės perdavimo funkcija su vėlavimu, abiem atvejais naudojant MPC reguliatorių ir PID reguliatorių, kuris suderintas trikdžio atžvilgiu, gauta mažesnė ISE kriterijaus vertė – atitinkamai 13 % ir 16 % lyginant su PID reguliatoriumi. Kai PID reguliatorius suderintas nuostato atžvilgiu gauta mažesnė IAE kriterijaus vertė naudojant PID reguliatorių – atitinkamai 47 % ir 48 %;
6. Atlikus PID reguliatoriaus valdymo kokybės palyginimą su MPC reguliatoriumi, taikant dviejų talpų proceso modelį, PID reguliatorių suderinus tiek trikdžio tiek nuostato atžvilgiu, ISE bei IAE kokybės kriterijaus vertės gautos mažesnės naudojant MPC reguliatorių. ISE – 38 %, IAE – 43 %;
7. Paklaidos ir reguliatorių valdymo signalo grafikuose matyti, kad MPC reguliatoriaus greita veika pasikeitus nuostato ar trikdžio reikšmei yra didesnė už PID reguliatorių, tačiau atliekant valdymo kokybės eksperimentus MPC reguliatoriui reikalingi didesni algoritmo skaičiavimo pajėgumai bei ilgesnis skaičiavimo laikas. Naudojant PID reguliatorių skaičiavimo laikas 2 – 3 sekundės, MPC – apie valandą;

8. Atsižvelgus į gautus valdymo kokybės rezultatus, nesudėtingų objektų optimizavimui efektyviau yra naudoti PID reguliatorius, kadangi pereinamojo proceso nusistovėjimo trukmė ir kiti reguliavimo kokybės parametrai yra panašūs, o nežymiai mažesnė MPC reguliatoriaus paklaida nėra patraukli praktiškai, atsižvelgiant į skaičiavimo laiką. MPC reguliatorius efektyviausias netiesinių objektų optimizavimui – ženkliai mažesnė kokybės kriterijaus paklaidos vertė, minimalus pereinamojo proceso perreguliavimas bei kur kas trumpesnis nusistovėjimo laikas lyginant su PID reguliatoriumi.

INFORMACIJOS ŠALTINIŲ SĄRAŠAS

1. K. S. Holkar, L. M. Waghmare. An Overview of Model Predictive Control. [žiūrėta 2016 kovo 28 d.] Prieiga per internetą: http://www.sersc.org/journals/IJCA/vol3_no4/5.pdf
2. Rui Huang. Nonlinear Model Predictive Control and Dynamic Real Time Optimization for Large-scale Processes. [žiūrėta 2016 kovo 28 d.]. Prieiga per internetą: <http://dynopt.cheme.cmu.edu/content/thesis/Huangthesis.pdf>
3. Manfred Morari, Jay H. Lee. Model predictive control: past, present, future. [žiūrėta 2016 kovo 29 d.] Prieiga per internetą: http://www.itk.ntnu.no/fag/fordypning/TK16-filer/Samling1_MorariLee.pdf
4. Frank Allgower, Rolf Findeisen, Zoltan K. Nagy. Nonlinear Model Predictive Control: From Theory to Application. [žiūrėta 2016 kovo 29 d.] Prieiga per internetą: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.568.5312&rep=rep1&type=pdf>
5. Alberto Bemporad, Manfred Morari. Robust Model Predictive Control: A Survey. [žiūrėta 2016 kovo 30 d.] Prieiga per internetą: <http://homes.esat.kuleuven.be/~maapc/static/files/CACSD/survey-robust-mpc.pdf>
6. R. D. Kotate, L. M. Waghmare. Review of Tuning Methods of DMC and Performance Evaluation with PID Algorithms on a FOPDT Model. [žiūrėta 2016 kovo 30 d.] Prieiga per internetą: http://www.sersc.org/journals/IJCA/vol4_no2/8.pdf
7. Jose Manuel Lopez-Guede, Borja Fernandez-Gauna. On the Influence of the Prediction Horizon in Dynamic Matrix Control. [žiūrėta 2016 kovo 30d.] Prieiga per internetą: <http://article.sapub.org/10.5923.j.control.20130301.03.html>
8. Rashmi Ranjan Kar. Dynamic Matrix Control. [žiūrėta kovo 30 d.] Prieiga per internetą: http://ethesis.nitrkl.ac.in/1878/1/angshu_thesis.pdf
9. M. Manimaran, S. Malaisamy. Parameter Identification and Dynamic Matrix Control Design for a Nonlinear Pilot Distillation Column. [žiūrėta kovo 30 d.] Prieiga per internetą: [http://sphinxsai.com/2015/ch_vol7_no1/5/\(382-388\)%20014.pdf](http://sphinxsai.com/2015/ch_vol7_no1/5/(382-388)%20014.pdf)
10. E. F. Camacho, C. Bordons. Model Predictive Control: Second Edition. [žiūrėta 2016 balandžio 1 d.] Prieiga per internetą: [http://een.iust.ac.ir/profs/Shamaghdari/MPC/Resources/Professor%20E.%20F.%20Camacho,%20Associate%20Professor%20C.%20Bordons%20\(auth.\)%20Model%20Predictive%20control%202007.pdf](http://een.iust.ac.ir/profs/Shamaghdari/MPC/Resources/Professor%20E.%20F.%20Camacho,%20Associate%20Professor%20C.%20Bordons%20(auth.)%20Model%20Predictive%20control%202007.pdf)

11. Jacques Richalet, Donal O'Donovan. Predictive Functional Control. [žiūrėta 2016 balandžio 2 d.] Prieiga per internetą: <http://een.iust.ac.ir/profs/Shamaghdari/MPC/Resources/Predictive%20Functional%20Control%202009.pdf>
12. John A. Rossiter, Robert Haber. The Effect of Coincidence Horizon on Predictive Functional Control. [žiūrėta 2016 balandžio 4 d.] Prieiga per internetą: <http://www.mdpi.com/2227-9717/3/1/25/htm>
13. H. Bouhenchir, M. Cabassud. Predictive functional control for the temperature control of a chemical batch reactor. [žiūrėta 2016 balandžio 5 d.] Prieiga per internetą: <https://core.ac.uk/download/files/437/12039964.pdf>
14. Minh Q. Phan. Unifying Input-Output and State-Space Perspectives of Predictive Control. [žiūrėta 2016 balandžio 6 d.] Prieiga per internetą: <http://www.dartmouth.edu/~mqphan/Resources/TP3044.pdf>
15. Andres Hernandez, Adriano Desideri. Real – Time Optimization of Organic Rankine Cycle Systems by Extremum – Seeking Control. [žiūrėta 2016 balandžio 7 d.] Prieiga per internetą: <http://www.mdpi.com/1996-1073/9/5/334/htm>
16. Juan A. Castano, Andres Hernandez. Implementation of Robust EPSAC on dynamic walking of COMAN Humanoid. [žiūrėta 2016 balandžio 7 d.] Prieiga per internetą: <http://www.nt.ntnu.no/users/skoge/prost/proceedings/ifac2014/media/files/0996.pdf>
17. Imre Benyo. Cascade Generalized Predictive Control – Applications in Power Plant Control. [žiūrėta 2016 balandžio 8 d.] Prieiga per internetą: <http://jultika.oulu.fi/files/isbn9514280326.pdf>
18. R. Kennel, A. Linder, M. Linke. Generalized Predictive Control. [žiūrėta 2016 balandžio 10 d.] Prieiga per internetą: <http://neuron-ai.tuke.sk/segedy/thesis/files/tyzden1/gpc52.pdf>
19. Lino O. Santos, Lorenz T. Biegler. A tool to analyze robust stability for model predictive controllers. [žiūrėta 2016 balandžio 8 d.] Prieiga per internetą: <https://estudogeral.sib.uc.pt/bitstream/10316/3839/1/file13cfc692967244ac8bf8fd99178466a1.pdf>
20. Howard Demuth, Mark Beale. Neural Network Toolbox. [žiūrėta 2016 balandžio 10 d.] Prieiga per internetą: http://www.image.ece.ntua.gr/courses_static/nn/matlab/nnet.pdf
21. Ramdane Henjar. Adaptive Neural Network Model Predictive Control. [žiūrėta 2016 balandžio 11 d.] Prieiga per internetą: <http://www.ijicic.org/ijicic-12-01040.pdf>
22. Piyush Shrivastana. Modeling and Control of CSTR using Model based Neural Network Predictive Control. [žiūrėta 2016 balandžio 11 d.] Prieiga per internetą: <https://arxiv.org/ftp/arxiv/papers/1208/1208.3600.pdf>

23. Ammar A. Aldair. Hardware Implementation of the Neural Network Predictive Controller for Coupled Tank System. [žiūrėta 2016 gegužės 5 d.] Prieiga per internetą: <http://pubs.sciepub.com/ajeec/2/2/2/>
24. Donatas Levišauskas. Automatinio reguliavimo sistemų derinimas. [žiūrėta 2016 gruodžio 1 d.] Prieiga per internetą: <https://www.ebooks.ktu.lt/eb/420/automatinio-reguliavimo-sistemu-derinimas/>