

Prediktivní řízení hladin ve spojených nádržích

Predictive control of levels in linked tanks

Bc. Karel Ševčík

Diplomová práce
2008



Univerzita Tomáše Bati ve Zlíně
Fakulta aplikované informatiky

Univerzita Tomáše Bati ve Zlíně
Fakulta aplikované informatiky
Ústav řízení procesů
akademický rok: 2007/2008

ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Karel ŠEVČÍK**
Studijní program: **N 2807 Chemické a procesní inženýrství**
Studijní obor: **Automatizace a řídicí technika**

Téma práce: **Prediktivní řízení hladin ve spojených nádržích**

Zásady pro vypracování:

1. Odvoďte zjednodušený matematický model soustavy tří spojených válcových nádrží, který odpovídá soustavě Amira DTS200.
2. Matematický model realizujte v prostředí Matlab / Simulink
3. Navrhněte prediktivní regulační algoritmy při řízení tohoto modelu. Pro návrh použijte diskrétní popis regulovaného systému a metodu ustupujícího horizontu (receding horizon).
4. Porovnejte vlastnosti regulačních pochodů pro různá nastavení prediktivního regulátoru.
5. Porovnejte regulační pochody naměřené na simulinkovém modelu a na reálné soustavě Amira DTS200. Zaměřte se na vliv rozdílnosti modelu a reálné soustavy.

Rozsah práce:

Rozsah příloh:

Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam odborné literatury:

1. Kwon, W. H. , Han, S. Receding Horizon Control. London: Springer-Verlag. 2005. 380 s. ISBN 1846280249.
2. Camacho, E. F. Model predictive control. London : Springer. 2004. 405 s. ISBN 1852336943.
3. Bobál, V. Identifikace systémů. Vysoké učení technické v Brně. 1990.
4. Bobál, V., J. Böhm, J. Fessl and J. Macháček. Digital Self-tuning Controllers: Algorithms, Implementation and Applications. Springer. 2005. ISBN 1852339802.
5. Qin, S. J., Badgwell, T. A. A survey of industrial model predictive control technology [online]. 2003 [cit 2008-01-28]. Dostupné z http://cepac.cheme.cmu.edu/pasilectures/darciodolak/Review_article_2.pdf.
6. DTS200 Laboratory Setup Three – Tank – System. Duisburg: Amira GmbH. 2002. 270s.

Vedoucí diplomové práce:

Ing. Petr Chalupa, Ph.D.

Ústav řízení procesů

Datum zadání diplomové práce:

22. února 2008

Termín odevzdání diplomové práce:

21. května 2008

Ve Zlíně dne 22. února 2008

prof. Ing. Vladimír Vašek, CSc.
děkan



prof. Ing. Petr Dostál, CSc.
ředitel ústavu

ABSTRAKT

Diplomová práce se zabývá porovnáním simulace a reálného měření pomocí prediktivního řízení hladin ve spojených nádržích na reálné soustavě Amira DTS200. Hlavním cílem je vytvoření matematického modelu soustavy a jeho následná realizace v programovém prostředí Matlab / Simulink. Dalším úkolem byl návrh prediktivního algoritmu pro řízení tohoto modelu pomocí metody ustupujícího horizontu. Závěrečným úkolem této práce bylo porovnat regulační pochody naměřené na simulinkovém modelu a na reálné soustavě Amira DTS200.

Klíčová slova: prediktivní regulátor, reálná soustava, matematický model, identifikace.

ABSTRACT

Diploma thesis deals with comparing of simulation and real measurement via predictive control of levels in the linked tanks on a real system Amira DTS200. The main aim is creation of mathematic model of system and its resulting realization in program software Matlab / Simulink. The other point was a design of predictive algorithm for control of this system via receding horizon method. The final point of this thesis was to compare the control courses measured on simulation model and real system Amira DTS200.

Keywords: predictive regulator, real system, mathematic model, identification.

Rád bych touto cestou poděkoval vedoucímu mé diplomové práce Ing. Petru Chalupovi Ph.D. za odborné vedení, rady a připomínky, které mi poskytoval při řešení této práce.

Prohlašuji, že jsem na diplomové práci pracoval samostatně a použitou literaturu jsem citoval. V případě publikace výsledků, je-li to uvolněno na základě licenční smlouvy, budu uveden jako spoluautor.

Ve Zlíně, 21.05.2008

.....
Podpis diplomanta

OBSAH

ÚVOD	7
I TEORETICKÁ ČÁST	8
1 PRINCIP PREDIKTIVNÍHO ŘÍZENÍ	9
1.1 MODEL Y.....	10
1.2 STRUKTURA PREDIKTIVNÍHO ŘÍZENÍ.....	15
1.3 OMEZUJÍCÍ PODMÍNKY.....	16
1.4 ODVOZENÍ PREDIKTIVNÍHO REGULÁTORU	17
2 IDENTIFIKACE SYSTÉMU	20
2.1 MATEMATICKÝ MODEL	20
2.2 FYZIKÁLNÍ VERSUS „BLACK BOX“ MODEL Y.....	22
2.3 METODA NEJMENŠÍCH ČTVERCŮ.....	23
2.3.1 Rekurzivní metoda nejmenších čtverců	25
II PRAKTICKÁ ČÁST	26
3 CÍLE PRAKTICKÉ ČÁSTI	27
4 SOUSTAVA SPOJENÝCH NÁDRŽÍ AMIRA DTS200	28
4.1 TECHNICKÉ PARAMETRY	28
4.2 ODVOZENÍ MATEMATICKÉHO MODEL U.....	31
4.2.1 Ustálený stav	33
4.2.2 Linearizace modelu	35
4.3 REALIZACE MATEMATICKÉHO MODEL U V PROSTŘEDÍ MATLAB / SIMULINK.....	37
5 PREDIKTIVNÍ ŘÍZENÍ SOUSTAVY AMIRA DTS200	38
5.1 NÁVRH PREDIKTIVNÍHO REGULAČNÍHO ALGORITMU	38
5.2 POROVNÁNÍ VLASTNOSTI REGULAČNÍCH POCHODŮ PRO RŮZNÁ NASTAVENÍ PREDIKTIVNÍHO REGULÁTORU	40
5.3 POROVNÁNÍ REGULAČNÍCH POCHODŮ SIMULINKOVÉM MODEL U A REÁLNÉ SOUSTAVY AMIRA DTS200.....	47
5.4 ONLINE IDENTIFIKACE.....	49
ZÁVĚR	55
CONCLUSION	56
SEZNAM POUŽITÉ LITERATURY	57
SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK	58
SEZNAM OBRÁZKŮ	61
SEZNAM TABULEK	63
SEZNAM PŘÍLOH	64

ÚVOD

Prediktivní řízení se rozvíjí od sedmdesátých let minulého století, kdy Richalet prezentoval Model Predictive Heuristic Control (MPHC) (později známý jako Model Algorithmic Control (MAC)), a také Cutler a Remakter představili Dynamic Matrix Control (DMC). Jednou z nejvíce populárních metod v současné době je Generalized Predictive Control (GPC).

Důvodem rozvoje prediktivního řízení je fakt, že představuje nejobecnější cestu návrhu řízení procesu podle zadaného kritéria. Prediktivní regulátory jsou zejména vhodné k nasazení v oblasti omezené znalosti o řízení. Prediktivní řízení dokáže předpovídat (predikovat) chování regulační smyčky na určitém časovém horizontu a počítat optimální trajektorii řízení při zohlednění saturačních limitů regulátoru, akčních členů, atd. V minulosti mohly být takové regulátory nasazeny pouze na velmi pomalé procesy nebo v nadřazené supervizorské úrovni řízení kvůli velké výpočetní náročnosti algoritmu predikce. Sféra použitelnosti se postupně rozšiřuje spolu se vzrůstajícím výkonem a rychlostí počítačů.

Předložená práce je věnována porovnání simulace a reálného měření pomocí prediktivního řízení hladin ve spojených nádržích na reálné soustavě Amira DTS200. Úkolem této práce bylo vytvoření matematického modelu soustavy a jeho následná realizace v programovém prostředí Matlab / Simulink. V dalším úkolu jsem se zabýval návrhem prediktivního algoritmu pro řízení tohoto modelu pomocí metody ustupujícího horizontu. Měření na reálné soustavě byla provedena pro různá nastavení prediktivního regulátoru. Závěrečným úkolem této práce bylo porovnat regulační pochody naměřené na simulinkovém modelu a na reálné soustavě Amira DTS200.

I. TEORETICKÁ ČÁST

1 PRINCIP PREDIKTIVNÍHO ŘÍZENÍ

Základní myšlenkou prediktivního řízení je použití přesného modelu k predikci výstupu procesu v budoucím časovém okamžiku. Známe tedy výstup procesu několik kroků dopředu (výhled predikce). Známe-li vývoj žádané hodnoty, můžeme vypočítat hodnoty akčního zásahu (výhled řízení). Akční zásah je vypočítán optimalizací daného kritéria, aby výstup procesu co nejlépe sledoval žádanou hodnotu. Toto kritérium má obvykle podobu kvadratické funkce rozdílu mezi predikovaným výstupem a žádanou hodnotou (účelová funkce). Ve většině případů je v účelové funkci obsažen také řídicí signál, jehož hodnoty je třeba penalizovat. Rozhodující roli v regulátoru hraje model procesu. Musí být schopný zachytit dynamiku a přesně predikovat výstupy. Návrh modelu není jedinečný, ale existuje řada různě formulovaných typů modelů. MPC patří do třídy počítačového algoritmu, který používá model systému k predikci budoucnosti odezvy na vstupní signál. Predikce je používána pro výpočet optimálního řízení.

Prediktivní řízení je ve své podstatě založeno na použití diskretních respektive vzorkovaných modelů procesů, a proto odvození příslušných řídicích algoritmů je realizováno hlavně v diskretní oblasti. Pod pojmem prediktivní řízení chápeme třídu metod řízení, které spojují určité společné charakteristiky 57[1]:

- Matematický model řízení systému je použitý na predikci budoucího řízení výstupu systému.
- Je znám průběh trajektorie žádané veličiny a regulované veličiny v budoucím čase.
- Výpočet posloupnosti budoucích řídicích zásahů zahrnuje minimalizaci vhodné účelové funkce (obvykle kvadratické) s budoucími trajektoriemi přírůstků řízení a regulační odchylky.
- Všechny akční zásahy musí být realizovatelné. Při metodě ustupujícího horizontu se však nerealizují všechny, jen několik ze začátku vypočtené sekvence.

Jednou z předností prediktivního řízení, je možnost uvažovat omezení vstupních a výstupní (případně stavových) veličiny přímo při návrhu regulátoru. Z tohoto důvodu je jeho použití vhodné v průmyslových aplikacích. Algoritmy prediktivního řízení jsou při řízení procesů mnohostranně použitelné a robustní. Kvalita řízení je obvykle vyšší ve srovnání s PID regulátory. Jsou aplikovatelné na neminimálně fázové, nestabilní a mnohazměrové procesy, a rovněž na procesy s dopravním zpožděním.

Obecně je výpočet akčního zásahu u prediktivního řízení založen na minimalizaci určitého kritéria. Existuje několik druhů kritérií např. **lineární** kritérium, které je založeno na součtu absolutních hodnot regulační odchylky e a změně akční veličiny du , nebo kritérium **minmax**, které sleduje jen maximální a minimální hodnotu regulační odchylky e a změnu akční veličiny du . Nejčastěji se používá kvadratické kritérium. Pro jednorozměrné systémy je možné zapsat kritérium v obecné formě

$$J(k) = \mathbf{e}^T \mathbf{Q}(k) \mathbf{e} + \Delta \mathbf{u}^T \mathbf{R}(k) \Delta \mathbf{u} \quad (1)$$

kde \mathbf{e} je vektor predikovaných regulačních odchylek, $\Delta \mathbf{u}$ je vektor budoucích diferencí akčního zásahu a čtvercové matice \mathbf{Q} a \mathbf{R} umožňují nastavit váhy jednotlivých prvků vektorů nebo jejich kombinací. Budoucí výstupy regulovaného systému a následně odpovídající regulační odchylky jsou počítány na základě lineárního diskrétního modelu regulovaného systému. Řídicí sekvence je získána minimalizací kritéria. Pro akční zásahy je aplikován postup receding horizon: pouze první vypočtený akční zásah ze sekvence je použit a v dalším kroku je prováděn výpočet celé sekvence akčních zásahů znovu.

1.1 Modely

V prediktivním řízení je možné používat libovolný model procesu. Vhodný model musí dostatečně vystihovat dynamické vlastnosti procesu. Nejčastěji se používají lineární modely, protože v případě bez omezení je možné analyticky vypočítat trajektorii akčních zásahů. Model procesu je potřebný pro výpočet predikce budoucí výstupní trajektorie. Některé modely v sobě přímo zahrnují modely poruch, v jiných se předpokládá, že poruchy jsou konstantní.

Impulsní odezva

Teoretická postupnost impulsní funkce je z praktických důvodů omezená jen na prvních několik členů. Tento model se potom označuje jako FIR (finite impulse response). Výstup je svázaný se vstupem vztahem

$$y(k) = \sum_{i=1}^N h_i u(k-i) = H(q^{-1})u(k) \quad (2)$$

kde $H(q^{-1}) = h_1 q^{-1} + h_2 q^{-2} + \dots + h_N q^{-N}$ je polynom N -tého stupně a q^{-1} je operátor zpětného posuvu definovaného vztahem $q^{-1}y(k) = y(k-1)$, $y(k)$, $u(k)$ a g_i jsou výstup systému, vstup systému a koeficienty impulsní odezvy.

Nevýhody tohoto modelu jsou:

- je potřebná vysoká hodnota N (50),
- může popisovat jen stabilní procesy.

Přechodová funkce

Model založený na přechodové funkci je velmi podobný FIR modelu a sdílí s ním i stejné nevýhody. Pro stabilní procesy se používá diskretní přechodová funkce omezená na prvních několik členů

$$y(k) = \sum_{i=1}^N g_i \Delta u(k-i) = G(q^{-1})(1 - q^{-1})u(k) \quad (3)$$

Protože přechodovou a impulsní charakteristiku lze velmi jednoduše získat, modely a prediktivní metody na nich založené jsou často používány v průmyslových aplikacích.

Přenosová funkce

Tento model je například použitý v metodě GPC (Generalized Predictive Control). Výstup je svázaný se vstupem vztahem

$$A(q^{-1})y(k) = B(q^{-1})u(k) \quad (4)$$

Výhodou tohoto modelu je jeho platnost i pro nestabilní procesy. Na druhé straně je nutné znát řád polynomů A , B .

Stavový popis

Model procesu v diskretním stavovém popisu je daný jako:

$$\begin{aligned} x(k+1) &= \mathbf{A}x(k) + \mathbf{B}u(k) \\ y(k) &= \mathbf{C}x(k) \end{aligned} \quad (5)$$

Jeho výhodou je stejný zápis jednorozměrových a mnohorozměrových systémů. Na druhé straně je potřebný pozorovatel stavu.

Jiné modely

Jako bylo výše uvedeno, je možné použít libovolné modely. Často se používají i spojité modely popsané systémem diferenciálních rovnic. Jejich nevýhodou je vysoká náročnost na simulaci a optimalizaci. V poslední době se často používají i jiné typy modelů, například neuronové sítě či fuzzy popisy. V tomto případě je model používán přímo, anebo jsou s ním jen generované některé charakteristiky procesu, jako skoková či impulsní odezva.

Lineárních stochastické modely

Následující modely mohou být použity pouze za předpokladu, že vyšetřovaný objekt je lineární, případně linearizovatelný. Tyto podmínky platí jen pro malou část reálných objektů, ale existuje řada metod jak modely linearizovat např. v okolí pracovních rozsahů. Stochastický systém může být popsán rovnicí [3]

$$y(k) = G(z^{-1})u(k) + n(k) \quad (6)$$

kde $u(t)$ / $y(t)$ jsou vstupní a výstupní veličiny modelu procesu, $G(z^{-1})$ je diskrétní přenosová funkce deterministické části modelu, z^{-1} je operátor zpětného posunutí, o kterém platí $y(k-1) = z^{-1}y(k)$ a $n(k)$ označuje náhodný "barevný" šum, který je generován průchodem bílého šumu $n_s(k)$ lineárním filtrem $H(z^{-1})$

$$n(k) = H(z^{-1})n_s(k) \quad (7)$$

Obě přenosové funkce $G(z^{-1})$ a $H(z^{-1})$ jsou obecně popsány podílem dvou polynomů, proto rovnice (6) může být převedena do tvaru

$$A(z^{-1})y(k) = z^{-d} \frac{B(z^{-1})}{F(z^{-1})}u(k) + \frac{C(z^{-1})}{D(z^{-1})}n_s(k) \quad (8)$$

kde d je počet kroků dopravního zpoždění. Jednotlivé polynomy mají následující tvar:

$$A(z^{-1}) = 1 + a_1z^{-1} + \dots + a_{na}z^{-na} \quad (9)$$


$$B(z^{-1}) = b_1z^{-1} + \dots + b_{nb}z^{-nb} \quad (10)$$

$$C(z^{-1}) = 1 + c_1z^{-1} + \dots + a_{nc}z^{-nc} \quad (11)$$

$$D(z^{-1}) = 1 + d_1z^{-1} + \dots + d_{nd}z^{-nd} \quad (12)$$

$$F(z^{-1}) = 1 + f_1z^{-1} + \dots + a_{nf}z^{-nf} \quad (13)$$

kde pro hloubky paměti platí $n_f \geq n_b, n_d \geq n_c$. Blokové schéma stochastického modelu je zobrazeno na



Obr. 1.1 Podrobné blokové schéma stochastického modelu

Několik nejvíce používaných typů stochastických modelů je uvedeno v Tab. 1.1.

Tab. 1.1 Klasifikace lineárních stochastických modelů

Zkratka	Název	Podmínky
ARX	AutoRegressive, eXogenous input	$C = D = F = 1$
AR	AutoRegressive	$B = 0, D = C = 1$
ARMA	AutoRegressive Moving Average	$B = 0, D = 1$
ARMAX	AutoRegressive Moving Average with eXogenous input	$D = F = 1$
OE	Output Error	$A = C = D = 1$
BJ	Box-Jenkins	$A = 1$
ARIMA	AutoRegressive Moving Average with Integrator	$D = 1 - z^{-1}, F = 1$

Obecně může být systém popsán použitím některého z těchto typů modelů ve tvaru

$$y(k) = \Theta^T(k) \varphi(k-1) + n_s(k) \quad (14)$$

kde $\varphi(k)$ je vektor dat a $\Theta(k)$ je vektor parametrů. Je zřejmé, že konečná reprezentace (14) závisí na výběru řádu modelů (na velikosti hodnot n_f, n_b, n_d, n_c) a vybraném typu modelu. Uvedeme si příklady dvou nejznámějších typů modelů, přičemž budeme předpokládat model druhého řádu, který se dá vyjádřit následující přenosovou funkcí

$$G(z^{-1}) = \frac{B(z^{-1})}{A(z^{-1})} = \frac{b_1 z^{-1} + b_2 z^{-2}}{1 + a_1 z^{-1} + a_2 z^{-2}} \quad (15)$$

ARX model

Mezi oblíbené a často používané modely patří model ARX, který se snadno implementuje a nezahrnuje v sobě přenosovou funkci poruchových veličin. Jestliže použijeme substituci $C(z^{-1}) = D(z^{-1}) = F(z^{-1}) = 1$ obdržíme model ARX, jehož rovnice je

$$y(k) = \begin{bmatrix} a_1 \\ a_2 \\ b_1 \\ b_2 \end{bmatrix} \begin{bmatrix} -y(k-1) & -y(k-2) & u(k-1) & u(k-2) \end{bmatrix} + n_s(k) \quad (16)$$

přičemž vektor parametrů a vektor dat jsou ve tvaru

$$\Theta^T = [a_1 \quad a_2 \quad b_1 \quad b_2] \quad (17)$$

$$\varphi(k-1) = [-y(k-1) \quad -y(k-2) \quad u(k-1) \quad u(k-2)] \quad (18)$$

ARX modely jsou používány v mnoha aplikacích řídicích algoritmů z důvodů snadné implementace, když se neuvažuje přenosová funkce poruchových veličin. V případě návrhu samočinně se nastavujícího regulátoru s průběžnou (rekurzivní) identifikací může tento typ modelu sloužit pro jeho aktualizaci využitím hodnot parametrů v předcházejícím kroku pro aktualizaci současných odhadů parametrů modelu a k výpočtu následujícího výstupu regulátoru.

ARMAX model

ARMAX obsahuje přenosovou funkci poruchových veličin. Kromě toho v případě použití modelů s klouzavým průměrem, které obsahují nenulové polynomy D nebo C , je obtížné odhadovat současné hodnoty parametrů polynomu C a simulovat bílý šum $n_s(k)$. V případě modelu ARMAX je uvažován vliv poruchových veličin, vyjádřený jejich přenosovou funkcí. Použitím tabulky 1 zavedeme substituci $D(z^{-1}) = F(z^{-1}) = 1$ a přenosová funkce $H(z^{-1})$ je podíl polynomů. V případě použití polynomů druhého stupně, můžeme tento přenos vyjádřit ve tvaru

$$H(z^{-1}) = \frac{C(z^{-1})}{A(z^{-1})} = \frac{1 + c_1 z^{-1} + c_2 z^{-2}}{1 + a_1 z^{-1} + a_2 z^{-2}} \quad (19)$$

Vektor parametrů a vektor dat jsou ve tvaru

$$\Theta^T = [a_1 \quad a_2 \quad b_1 \quad b_2 \quad c_1 \quad c_2] \quad (20)$$

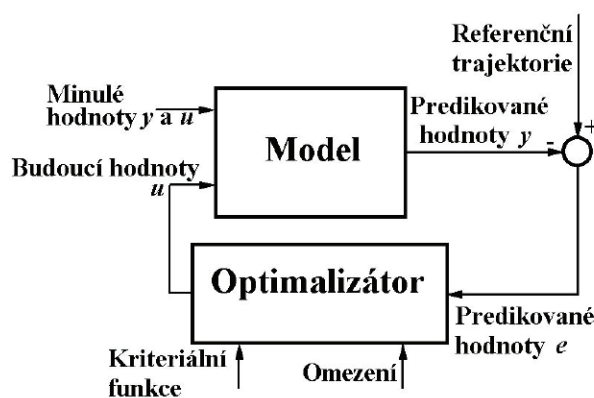
$$\varphi(k-1) = \begin{bmatrix} -y(k-1) & -y(k-2) & u(k-1) \\ u(k-2) & n_s(k-1) & n_s(k-2) \end{bmatrix} \quad (21)$$

Je zřejmé, že odhad chyby výstupu je modelován prostřednictvím výstupu $n(k)$ lineárního filtru $H(z^{-1})$, jehož vstupní veličinou je bílý šum $n_s(k)$. Bohužel, použití takového filtru může způsobit zavedení nestability do procesu nebo zhoršení odhadu parametrů při průběžné identifikaci. Z tohoto důvodu se v praktických aplikacích podstatně ve větší míře používá ARX model.

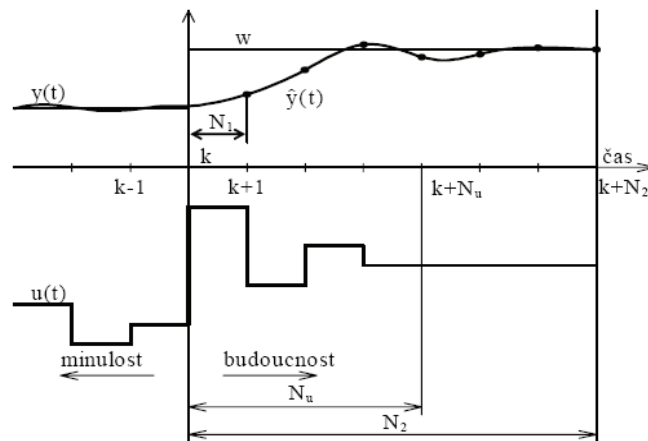
1.2 Struktura prediktivního řízení

Základní struktura systému prediktivního řízení je uvedena na Obr. 1.2 [1], jeho princip, uvedený na Obr. 1.3, je následující:

1. Model řízeného procesu je explicitní součástí regulátoru a je používán na predikci N budoucích výstupů procesu \hat{y} . Predikce jsou vypočítané vzhledem k informacím dostupným do času k a vzhledem k neznámé trajektorii akčních zásahů, které je třeba určit.
2. Trajektorie budoucích akčních zásahů je určena z řešení optimalizačního problému, obsahující vhodnou účelovou funkci a omezení. Účelová funkce zahrnuje budoucí predikce výstupu, budoucí trajektorii žádané veličiny a trajektorii budoucích akčních zásahů.
3. I když v předešlém kroku byla počítána celá trajektorie akčních zásahů, jen první člen $u(k)$ je použit pro řízení procesu. V další periodě vzorkování se celý postup opakuje. Tento princip je známý jako *strategie ustupujícího horizontu*.



Obr. 1.2 Základní struktura systému prediktivního řízení



Obr. 1.3 Princip prediktivního řízení (N_1 , N_2 , N_u – minimální, maximální, výhled řízení)

1.3 Omezující podmínky

V praxi se velmi často setkáváme s omezeními (constraints). Často se jedná o fyzická omezení ať už senzorů, či akčních členů, technologická či jiná omezení procesů. Nejčastěji jsou omezovány veličiny na vstupu, které mohou pracovat pouze v určitém rozsahu hodnot (např. průtoky tekutin nemohou být negativní, ventil může být otevřen maximálně na 100 %). Kromě toho existují však i určitá doporučení a limity pro výstupní veličiny procesů (s ohledem na životní prostředí či bezpečnost pracovišť). Schopnost práce s omezeními je jednou z hlavních předností prediktivního řízení, která měla vliv na rozšíření MPC v průmyslu. Velké množství průmyslových procesů je totiž řízeno na hodnotách blížících se omezujícím podmínkám, nebo přímo na nich. Z tohoto faktu vyplývá požadavek na optimální řízení v rámci omezení.

Nejjednodušším a v praxi nejpoužívanějším způsobem aplikace omezení je analytické řešení optimalizační úlohy bez omezení a následná aplikace omezení – saturace na výsledek. Toto řešení je jednoduché, ale nezaručí optimální řízení podle námi zvolených kritérií. Další nevýhodou je také to, že takovéto omezení lze aplikovat pouze na veličiny vystupující z algoritmu optimalizace (akční zásah a změna akčního zásahu). Vhodnějším řešením je tedy řešit optimalizační úlohu již s danými omezeními. Tento přístup umožní omezit nejen výstupní veličiny algoritmu, ale také samotný výstup soustavy a v případě stavového modelu i jednotlivé vnitřní stavy systému. Omezení rozlišujeme jako tvrdá (hard constraints) a měkká (soft constraints).

- tvrdá omezení jsou fyzická omezení procesů, jejichž hranice v prostoru řešení nelze za žádných okolností překročit. Tvrdá představují omezující podmínky řešení kritéria.
- měkká omezení jsou ta, která mohou být za určitých podmínek porušena. Měkká omezení vstupují do optimalizace jako část účelové funkce.

1.4 Odvození prediktivního regulátoru

V následující kapitole bude odvozen a popsán návrh prediktivního regulátoru a jeho modifikace pro použití kvadratického programování, které je použito pro všechna měření v praktické části na reálném modelu Amira DTS200. Prediktivní regulátor je založen na principu minimalizace kritéria. Bylo zvoleno následující kritérium:

$$J = \sum_{i=k}^{i=k+N} e^2(k) + \lambda \sum_{i=k}^{i=k+N} [\Delta u(k)]^2 \quad (22)$$

Šum vyskytující se při měření je uvažován jako bílý šum a tedy není v kritériálních rovnicích uvažován. Odvození vychází z diskrétního přenosu soustavy ARX modelu:

$$Y(z^{-1}) = \frac{b_1 z^{-1} + b_2 z^{-2}}{1 + a_1 z^{-1} + a_2 z^{-2}} U(z^{-1}) \quad (23)$$

který má diferenciální rovnici ve tvaru

$$y(k) + a_1 y(k-1) + a_2 y(k-2) = b_1 u(k-1) + b_2 u(k-2) \quad (24)$$

V dalších krocích má rovnice tvar

$$\begin{aligned} y(k+1) + a_1 y(k) + a_2 y(k-1) &= b_1 u(k) + b_2 u(k-1) \\ \vdots & \\ y(k+N) + a_1 y(k+N-1) + a_2 y(k+N-2) &= b_1 u(k+N-1) + b_2 u(k+N-2) \end{aligned} \quad (25)$$

V těchto rovnicích jsou ovlivnitelné hodnoty $y(k+1) \dots y(k+N)$ současnou hodnotu regulované veličiny tedy $y(k)$ již není možné ovlivnit. Budoucí hodnoty regulované veličiny můžeme ovlivnit pomocí akčních zásahů v krocích $u(k) \dots u(k+N-1)$.

Obecně platí

$$\mathbf{AY} = \mathbf{BU} \quad (26)$$

$$\left[\begin{array}{cc|cccc} a_2 & a_1 & 1 & \cdots & 0 \\ 0 & a_2 & a_1 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \ddots & \ddots & \vdots \\ 0 & \cdots & & a_2 & a_1 & 1 \end{array} \right] \begin{array}{c} y(k-1) \\ \underline{y(k)} \\ \vdots \\ y(k+N) \end{array} = \left[\begin{array}{cccc|cc} b_2 & b_1 & \cdots & 0 \\ 0 & b_2 & b_1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ 0 & \cdots & \cdots & b_2 & b_1 \end{array} \right] \begin{array}{c} \underline{u(k-1)} \\ u(k) \\ \vdots \\ u(k+N-1) \end{array} \quad (27)$$

$N \times N + 2$ $N + 2 \times 1$ $N \times N + 1$ $N + 1 \times 1$

Maticice \mathbf{A} , \mathbf{B} , \mathbf{Y} , \mathbf{U} jsou rozděleny na dvě části. Hodnotu částí \mathbf{X}_t není možné ovlivnit.

Hodnotu částí \mathbf{X}_p je možné ovlivnit v dalších krocích.

$$\left[\mathbf{A}_t | \mathbf{A}_p \right] \times \begin{bmatrix} \mathbf{Y}_t \\ \mathbf{Y}_p \end{bmatrix} = \left[\mathbf{B}_t | \mathbf{B}_p \right] \times \begin{bmatrix} \mathbf{U}_t \\ \mathbf{U}_p \end{bmatrix} \quad (28)$$

$$\begin{aligned} \mathbf{A}_t \mathbf{Y}_t + \mathbf{A}_p \mathbf{Y}_p &= \mathbf{B}_t \mathbf{U}_t + \mathbf{B}_p \mathbf{U}_p \\ \mathbf{Y}_p &= \mathbf{A}_p^{-1} (\mathbf{B}_t \mathbf{U}_t + \mathbf{B}_p \mathbf{U}_p - \mathbf{A}_t \mathbf{Y}_t) \end{aligned} \quad (29)$$

$$\mathbf{E} = \begin{bmatrix} e(k+1) \\ \vdots \\ e(k+N) \end{bmatrix} \quad \mathbf{W} = \begin{bmatrix} w(k+1) \\ \vdots \\ w(k+N) \end{bmatrix} \quad (30)$$

$$\mathbf{E} = \mathbf{W} - \mathbf{Y}_p = \mathbf{W} - \mathbf{A}_p^{-1} (\mathbf{B}_t \mathbf{U}_t - \mathbf{A}_t \mathbf{Y}_t) - \mathbf{A}_p^{-1} \mathbf{B}_p \mathbf{U}_p = \mathbf{W}_m - \mathbf{A}_p^{-1} \mathbf{B}_p \mathbf{U}_p \quad (31)$$

$$\mathbf{E}^T \mathbf{E} = \sum_{i=k+1}^N e^2(i) \quad (32)$$

Po dosazení za \mathbf{E} dostaneme:

$$\begin{aligned} \mathbf{E}^T \mathbf{E} &= \mathbf{W}_m^T \mathbf{W}_m - 2 (\mathbf{W}_m^T \mathbf{A}_p^{-1} \mathbf{B}_p \mathbf{U}_p) + \mathbf{U}_p^T \mathbf{B}_p^T (\mathbf{A}_p^{-1})^T \mathbf{A}_p^{-1} \mathbf{B}_p \mathbf{U}_p \\ &\Downarrow \end{aligned} \quad (33)$$

$$J_1 = \frac{1}{2} \mathbf{U}_p^T \underbrace{(\mathbf{B}_p^T (\mathbf{A}_p^{-1})^T \mathbf{A}_p^{-1} \mathbf{B}_p)}_{\hat{H}_1} \mathbf{U}_p + \underbrace{(-\mathbf{W}_m^T \mathbf{A}_p^{-1} \mathbf{B}_p)}_{\hat{f}_1} \mathbf{U}_p$$

$$\Delta \mathbf{U} = \begin{bmatrix} \Delta u(k) \\ \vdots \\ \Delta u(k+N-1) \end{bmatrix} = \left[\begin{array}{ccc|ccc} -1 & 1 & 0 \\ 0 & -1 & 1 \\ \vdots & \vdots & \ddots \\ 0 & \cdots & -1 & 1 \end{array} \right] \begin{bmatrix} \underline{u(k-1)} \\ u(k) \\ \vdots \\ u(k+N-1) \end{bmatrix} \quad (34)$$

$$\Delta \mathbf{U} = \mathbf{R}_t \mathbf{U}_t + \mathbf{R}_p \mathbf{U}_p \quad (35)$$

$$\lambda \sum (\Delta u(k))^2 = \lambda (\Delta \mathbf{U})^T \Delta \mathbf{U} \quad (36)$$

Po dosazení za ΔU dostaneme

$$J_2 = \lambda \mathbf{U}_t^T \mathbf{R}_t^T \mathbf{R}_t \mathbf{U}_t + 2 \underbrace{\lambda \mathbf{U}_t^T \mathbf{R}_t^T \mathbf{R}_p}_{f_2} \mathbf{U}_p + \mathbf{U}_p^T \underbrace{\lambda \mathbf{R}_p^T \mathbf{R}_p}_{H_2} \mathbf{U}_p \quad (37)$$

Absolutní člen nemá na výpočet \mathbf{U}_p vliv a tedy kritérium je možné psát jako (37)

$$\begin{aligned} H &= H_1 + H_2 & f &= f_1 + f_2 \\ J &= \frac{1}{2} \mathbf{U}_p^T H \mathbf{U}_p + f^T \mathbf{U}_p \end{aligned} \quad (38)$$

Jak již bylo řečeno v úvodu kapitoly, prediktivní regulátor byl navržen s modifikací pro použití funkce v programovém prostředí Matlab/Simulink `quadprog` tedy kvadratické programování. Aby bylo možné tuto funkci použít bylo nutné rovnice upravit do následujícího tvaru:

$$\min_x \frac{1}{2} x^T H x + f^T x \quad (39)$$

Neznámou x v našem případě představuje matice budoucích hodnot \mathbf{U}_p .

2 IDENTIFIKACE SYSTÉMU

Cílem identifikace je vytvořit model systému tak, aby jeho chování bylo (nejčastěji z hlediska minima kriteria) co nejpodobnější jako u systému za stejných provozních podmínek. Jedná se vždy o aproximaci, která transformuje skutečnost do světa matematiky. Důležitou úlohu při procesu identifikace hraje informace:

- Empirická – získává se pozorováním objektu (měřením), má kvantitativní charakter.
- Apriorní – spočívá ve využití již existujících poznatků (matematických vztahů) o celé třídě a příbuzných třídách objektů, kam zkoumaný objekt patří. Má rozhodující význam na strukturu modelu a kvalitativní charakter.

Tyto dvě informace představují úplnou informaci o systému. Úspěšnost modelování a identifikace závisí na vhodném výběru:

- Apriorní informace
- Empirické informace
- Identifikačního algoritmu

Předpokladem efektivního řízení daného objektu je znalost jeho vlastností. Čím více má být kvalita řízení lepší, tím dokonaleji a přesněji musíme znát vlastnosti řízeného objektu.

2.1 Matematický model

Matematický model procesu je matematické vyjádření vztahů mezi veličinami, které proces popisují. Dynamické chování je chování procesu (systému) v závislosti na čase, matematickým popisem jsou diferenciální rovnice.

Matematické modely:

- získané zpracováním experimentů (induktivní) matematický popis je formální, systém je považován za „černou skříňku“, zpracováním naměřených dat určíme hodnoty parametrů zvoleného matematického popisu.
- získané fyzikální analýzou procesu (deduktivní, deterministické) matematický popis vyjadřuje podstatu procesu, vychází z fyzikálních, fyzikálně-chemických a chemických zákonů, kterými se proces řídí.

Analýza procesu

- specifikace dějů probíhajících v procesu a určení jejich podstaty

- vymezení vlivů působících na proces
- určení veličin (fyzikálních,...) popisujících proces
- výběr dílčích dějů a vlivů podstatných pro popis procesu
- výběr možných zjednodušení a jejich realizace

Poslední dva výběry mají rozhodující vliv na kvalitu modelu. V úvahách při tvorbě je nutné vycházet z účelu vytvářeného modelu a začínat od co nejjednoduššího modelu. Pro zjednodušení modelu je proto nezbytné některé jevy zanedbat např. zanedbávání ztrát, nezávislost látkových vlastností na stavových veličinách, rozdělení systému na subsystemy, linearizace nelineárních závislostí, zjednodušování geometrických proporcí, volba vhodné souřadnicové soustavy, atd.

K vytvoření přesného matematického popisu je zapotřebí vhodný výběr matematického vyjádření vztahů použitých v teoretickém modelu, vytvoření modelových rovnic a jejich základní kontrola a v neposlední řadě určení podmínek řešení (počátečních, okrajových).

Takto vytvořené matematické modely je potřebné na závěr zkontrolovat z hlediska: zachování ustálených stavů, reálnosti výsledků simulace pro mezní stavy, porovnáním simulovaných časových průběhů se známými daty, atd.

Dalším možným způsobem vytvoření matematického modelu je použití **matematické bilance**. Bilance je vztah založený na aplikaci zákonů o zachování. Nejčastěji se setkáváme s bilancemi hmotnosti, energie a hybnosti. Aby bylo možno sestavit bilanční vztah, musíme nejprve definovat bilancovaný systém a bilanční období. Systém je část prostoru tvořící obvykle souvislou oblast. Tato oblast je omezena hranicí, která může a nemusí k systému patřit. Tvoří-li systém část trojrozměrného prostoru, nezývá se hranice systémů také kontrolní plocha. Bilanční období je obvykle spojitý uzavřený časový interval. Jak systém, tak bilanční období mohou být diferenciální i integrální. Vhodná volba systému a bilančního období podle povahy úlohy je důležitá pro její úspěšné řešení. Zákon o zachování bilancované veličiny vyjadřuje, že v izolovaném systému, tj. v systému, jehož hranicí bilancovaná veličina neprochází, zůstává množství bilancované veličiny během libovolného bilančního období konstantní. Bilancovat však lze i u takových systémů, které nejsou uzavřené a u nichž dochází ke vzniku nebo zániku bilancované veličiny chemickou reakcí. Pro tyto bilanční vztahy je charakteristické, že obsahují členy vyjadřující výměnu bilancované veličiny mezi systémem a okolím, a

zdrojový člen. Mezi bilančními vztahy pro různé druhy veličin platí určité matematické analogie [4]. To umožňuje sestavit obecnou kvantitativní formulaci bilanční rovnice:

$$\text{AKUMULACE} = \text{VSTUP} - \text{VÝSTUP} + \text{ZDROJ} \quad (40)$$

- **AKUMULACE** změna množství (zádrže) bilancované veličiny uvnitř bilancovaného systému za bilanční časový interval,
- **VSTUP** – množství bilancované veličiny, které za bilanční časový interval vstoupí z okolí přes rozhraní do bilancovaného systému,
- **VÝSTUP** – množství bilancované veličiny, které za bilanční časový interval vystoupí z bilancovaného systému přes rozhraní do okolí,
- **ZDROJ** – množství bilancované veličiny, které za bilanční časový interval přeměnou uvnitř bilancovaného systému vznikne (znaménko +) nebo zanikne (znaménko -).

Při řešení bilanční úlohy je možno sestavit bilanční vztah pro libovolné bilancované veličiny, systémy a bilanční období. Z hlediska vlastního výpočtu mají význam pouze vztahy, které jsou navzájem nezávislé a obsahují neznámé proměnné potřebné k řešení bilanční úlohy.

2.2 Fyzikální versus „black box“ modely

Fyzikální modely („white box“) se získávají tzv. matematicko-fyzikální analýzou, při které je systém rozebrán na malé součásti, pro které jsou napsány známé základní rovnice popisující jejich chování na základě fyzikálních zákonů a pravidel. Metody vytvářející takové modely vycházejí z principů zachování energie a rovnováhy sil a momentů (např. metody „Bond’s“ grafů, Lagrangeovy rovnice, ...). Tento přístup k modelování sebou přináší specifické problémy. Pro složitější systémy se počet parametrů začíná neúnosně zvyšovat a i simulace potom může být pomalá, v reálném čase i nemožná. Např. pro použití modelů některých složitých systémů pro školení obsluhy (na simulátorech), je někdy třeba je zjednodušit tak, aby mohly na současných počítačích běžet v reálném čase. Dalším specifickým problémem je to, že asi nikdy nepostihneme složitost a transparentnost přírody zcela, ale musíme si zvolit úroveň, do které se chceme ponořit.

„*Black box*“ modely stojí na opačné straně spektra. Tyto modely aproximují chování systému bez jakýchkoliv nároků na informace o systému vlastním. Není ani důležité co jednotlivé vstupy a výstupy ve skutečnosti znamenají a v jakých jednotkách se udávají. Parametry těchto modelů nemají žádný fyzikální význam. Např. jakékoliv měření můžeme s určitou přesností aproximovat polynomem

$$y_m = p_1 + p_2 t + p_3 t^2 + \dots, \quad (41)$$

jestliže stupeň polynomu bude dostatečně vysoký. Takový model bude samozřejmě mít velice špatné schopnosti předvídat chování obecného dynamického systému, protože vůbec nerespektuje vstupy do systému [6].

Tab. 2.1 Shrnutí vlastností "White box" a "Black box" modelu

MODELY		
	"White box"	"Black box"
Parametry	mají konkrétní význam	nemají konkrétní význam
Simulace	dlouhá a složitá	rychlá a jednoduchá
Fyzikální informace o systému	mohou být zahrnuty viditelně	většinou nebrány v úvahu
Oblast platnosti modelu	velká (jestliže je správná struktura)	omezená

2.3 Metoda nejmenších čtverců

Metoda nejmenších čtverců je matematická metoda, určená ke statistickému zpracování dat. Jejím úkolem je nalézt vhodnou aproximační funkci pro dané empiricky zjištěné hodnoty. Daný je přitom rovněž parametrizovaný analytický předpis pro hledanou funkci – hledají se tedy vlastně jenom hodnoty těchto parametrů. Metoda nejmenších čtverců hledá takovou funkci, že součet čtverců odchylek jejích funkčních hodnot od daných naměřených hodnot je nejmenší možný.

Předpokládejme, že máme zadánu řadu bodů $[x_i; y_i]$, $i = 0; \dots; n$. Těmito body chceme proložit aproximační polynom ve tvaru

$$p_m(x) = a_0 + a_1 x + \dots + a_m x^m = \sum_{j=0}^m a_j x^j, \quad (42)$$

Stupeň polynomu bývá většinou podstatně nižší (např. $m=2$) než počet bodů (např. $n=1000$). V případě, že se počet bodů rovná stupni polynomu, bude polynom body přímo procházet a bude se tedy jednat o interpolaci [8]. Budeme požadovat, aby součet kvadrátů odchylek $f(x_i)$ od aproximační funkce $p_m(x_i)$ byl co nejmenší. Tento součet E je

$$E = \sum_{i=0}^n e_i^2 = \sum_{i=0}^n [p_m(x_i) - f(x_i)]^2 = \sum_{i=0}^n \left[\sum_{j=0}^m a_j x_i^j - f(x_i) \right]^2 \quad (43)$$

Tento součet je funkcí koeficientů polynomu a_k . Aby tento součet byl minimální, musí být první derivace nulová. Dosadíme vyjádření chyby (42) a upravíme

$$\begin{aligned} \frac{\partial E}{\partial a_k} &= \frac{\partial}{\partial a_k} \left(\sum_{i=0}^n \left[\sum_{j=0}^m a_j x_i^j - f(x_i) \right]^2 \right) = \sum_{i=0}^n \sum_{j=0}^m \frac{\partial}{\partial a_k} [a_j x_i^j - f(x_i)]^2 = \\ &= \sum_{i=0}^n \sum_{j=0}^m 2 [a_j x_i^j - f(x_i)] \frac{\partial}{\partial a_k} [a_j x_i^j - f(x_i)] = \sum_{i=0}^n \sum_{j=0}^m 2 [a_j x_i^j - f(x_i)] x_i^k = \\ &= 2 \sum_{i=0}^n \sum_{j=0}^m [a_j x_i^{j+k} - f(x_i) x_i^k] = 2 \left(\sum_{j=0}^m a_j \sum_{i=0}^n x_i^{j+k} - \sum_{i=0}^n f(x_i) x_i^k \right) = 0 \end{aligned} \quad (44)$$

Pokud zavedeme označení

$$S_k = \sum_{i=0}^n x_i^k, \quad T_k = \sum_{i=0}^n f(x_i) x_i^k \quad (45)$$

dostaneme

$$\sum_{j=0}^m a_j S_{j+k} - T_k = 0 \quad (46)$$

Dostali jsme tedy soustavu lineárních rovnic

$$\begin{aligned} S_0 a_0 + S_1 a_1 + \dots + S_m a_m &= T_0 \\ S_1 a_0 + S_2 a_1 + \dots + S_{m+1} a_m &= T_1 \\ \vdots & \\ S_m a_0 + S_{m+1} a_1 + \dots + S_{2m} a_m &= T_m \end{aligned} \quad (47)$$

v maticovém zápisu

$$\begin{bmatrix} S_0 & S_1 & \dots & S_m \\ S_1 & S_2 & \dots & S_{m+1} \\ \vdots & \vdots & \ddots & \vdots \\ S_m & S_{m+1} & \dots & S_{2m} \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ \vdots \\ a_m \end{bmatrix} = \begin{bmatrix} T_0 \\ T_1 \\ \vdots \\ T_m \end{bmatrix} \quad (48)$$

Z této soustavy můžeme určit koeficienty polynomu a_k .

2.3.1 Rekurzivní metoda nejmenších čtverců

Rekurzivní metody identifikace hrají důležitou roli při zajištění sledování časově proměnlivých parametrů modelu dynamického procesu. Při této identifikaci se používají nově naměřené hodnoty pouze pro opravu (korekci) původních odhadů, čímž klesá výpočetní složitost identifikačních algoritmů oproti jednorázové metodě nejmenších čtverců a tedy i náročnost na použitou výpočetní techniku. Rekurzivní algoritmy umožňují sledovat změny vlastností (parametrů) procesu v reálném čase a proto jsou základem samočinně se nastavujících regulátorů. Rekurzivní (rekurentní) algoritmy jsou vhodné pro tzv. průběžnou identifikaci, tj. pro odhad parametrů modelu v reálném čase. O neměřitelné náhodné složce $e_s(k)$ předpokládáme, že je posloupností vzájemně nekorelované náhodné veličiny a rovněž nekorelované se vstupem a výstupem procesu. Dále předpokládáme, že náhodná veličina má nulovou střední hodnotu a konstantní kovarianci (rozptyl). Výhodou rekurzivní metody nejmenších čtverců je ta skutečnost, že potřebuje nejmenší objem apriorních informací o náhodné složce $e_s(k)$. Tato metoda může být použita pro odhad parametrů modelu ARX. Algoritmus rekurzivní metody nejmenších čtverců je dán následujícími vztahy

$$\hat{e}(k) = y(k) - \phi^T(k) \hat{\Theta}(k-1) \quad (49)$$

$$\mathbf{L}(k) = \frac{\mathbf{C}(k-1) \phi(k)}{1 + \phi^T(k) \mathbf{C}(k-1) \phi(k)} \quad (50)$$

$$\hat{\Theta}(k) = \hat{\Theta}(k-1) + \mathbf{L}(k) \hat{e}(k) \quad (51)$$

$$\mathbf{C}(k) = \mathbf{C}(k-1) - \mathbf{L}(k) \phi^T(k) \mathbf{C}(k-1) \quad (52)$$

kde $\mathbf{L}(k)$ značí matici zesílení, $\mathbf{C}(k)$ je kovarianční matice odhadovaných parametrů, $\hat{\Theta}(k)$ je vektor odhadovaných parametrů a $\phi(k)$ je tzv. regresní vektor (vektor dat).

$$\hat{\Theta}^T(k) = [a_1 \dots a_{na}, b_1 \dots b_{nb}] \quad (53)$$

$$\phi^T(k) = [-y(k-1), \dots, -y(k-na), u(k-1), \dots, u(k-nb)] \quad (54)$$

Základní algoritmus rekurzivní metody nejmenších čtverců předpokládá, že parametry modelu procesu jsou konstantní. V mnoha případech, je ale požadováno, aby bylo možno sledovat změny v množině parametrů. V takovém případě je nezbytné, zavést do základního algoritmu úpravu, která zajistí sledování časově proměnlivých parametrů.

II. PRAKTICKÁ ČÁST

3 CÍLE PRAKTICKÉ ČÁSTI

Praktická část diplomové práce se zabývala následujícími úkoly:

- Odvození zjednodušeného matematického modelu soustavy tří spojených válcových nádrží, který odpovídá soustavě Amira DTS200.
- Realizace matematického modelu v prostředí Matlab / Simulink.
- Návrh prediktivní regulačního algoritmu při řízení tohoto modelu. Pro návrh byl použit diskretní popis regulovaného systému a metoda ustupujícího horizontu (receding horizon).
- Porovnání vlastností regulačních pochodů pro různá nastavení prediktivního regulátoru.
- Porovnání regulačních pochodů naměřených na simulinkovém modelu a na reálné soustavě Amira DTS200. Zaměření se na vliv rozdílnosti modelu a reálné soustavy.

4 SOUSTAVA SPOJENÝCH NÁDRŽÍ AMIRA DTS200



Obr. 4.1 Reálná soustava Amira DTS200

Soustava Amira DTS200 obsahuje tři nádrže T1, T2 a T3. Tyto nádrže jsou navzájem propojeny přes ventily. Každá nádrž má ještě navíc jeden ventil, kterým se z nádrže kapalina vypouští do zásobníku, odkud se zpět transportuje čerpadly Č1 a Č2. Čerpadlo Č1 dodává kapalinu do nádrže T1 a čerpadlo Č2 do nádrže T3. Nádrž T2 je tedy bez čerpadla a kapalina se do ní může dostat pouze přes boční ventily z nádrží T1 a T3. Sensory měřící výšku hladiny, pohony ovládající polohu ventilu a řízení výkonu čerpadla jsou kabely napojeny do zesilovače, který umožňuje přepnutí mezi manuálním ovládáním a ovládáním přes PC. V nádržích je výška kapaliny měřena deskovým kapacitním senzorem. Zesilovač obsahuje také D/A a A/D převodník, a odtud jsou data vedena do PC.

4.1 Technické parametry

Propojení PC a zesilovače zajišťuje karta Adventech PCI 1716. V následujících tabulkách budou uvedeny jednotky programu Matlab (dále používáno jako MU) a tomu odpovídající stavy ventilů, čerpadel a senzorů výšky hladiny.

Tab. 4.1 Napětí jdoucí z ventilů na analogovou kartu

Ventil	Otevřený	Zavřený
V1	-0,6938	0,5146
V2	-0,7539	0,457
V3	-0,6504	0,543
V4	-0,7129	0,4966
V5	-0,6772	0,4834
V6	-0,6528	0,5229


Tab. 4.2 Napětí jdoucí z nádrží na analogovou kartu

Nádrž	Maximální výška hladiny 600mm	Minimální výška hladiny 0mm
T1	-0,8825	0,8982
T2	-0,9028	0,8795
T3	-0,7902	0,9819

Tab. 4.3 Napětí jdoucí z čerpadel na analogovou kartu

Čerpadlo	Maximální výkon čerpadla	Minimální výkon čerpadla
Č1	1	-1
Č2	1	-1

V prvním měření byla ověřena závislost výstupu ze senzoru na výšce hladiny. Jak je vidět z grafu závislost je lineární. Linearizaci jsme také získali přepočít z MU na výšku hladiny v mm.




Obr. 4.2 Závislost napětí na senzoru na výšce hladiny

Dalším měřením bylo zjištění skutečného průtoku (výkonu) čerpadla a jeho porovnání s hodnotou uvedenou v manuálu. Před měřením byly všechny ventily nastaveny do pozice zavřeno a čerpadla nastavena na konstantní hodnotu výkonu. Měření byla provedena pro 25%, 50%, 75% a 100% výkonu čerpadel. Z naměřených dat byla pro nás důležitá změna výšky hladiny za jednotku času. Jelikož výstup ze senzoru obsahoval šum, byla data proložena přímkou (Matlab funkce `polyfit`). Z této přímky byla následně získána změna hladiny v jednotkách [mm/s]. Pro porovnání s tabulkovou hodnotou bylo nutné průtok převést na jednotky [l/min].

$$[\text{l/min}] = \frac{10^6}{60A} [\text{mm/s}], \quad (55)$$


kde A představuje plochu podstavy jedné nádrže. Tabulková hodnota maximálního průtoku čerpadla je 7 l/min. Měřením byla získána hodnota 6,982 l/min.



Obr. 4.3 Závislost změny výšky hladiny [mm/s] na výkonu čerpadla Č1 [%]

Posledním údajem, který bylo zapotřebí získat, byla charakteristická konstanta ventilu k . Hodnota konstanty ventilu charakterizuje poměry průtoku a tlakové ztráty. Z naměřených dat bylo zjištěno, že ventil je značně nelineární. Lineární byl pouze v oblasti 40% – 60% otevření ventilu. Z tohoto důvodu nebyl ventil použit jako regulační orgán. Regulačním orgánem bylo zvoleno čerpadlo, které vykazovalo lineární závislost v celém rozsahu svého


výkonu. Na hodnotu konstanty k mělo také vliv, jestli byl ventil nastaven do polohy z otevřené nebo uzavřené polohy. Tento rozdíl je znatelný z Obr. 4.4.



Obr. 4.4 Závislost pozice ventilu na hodnotě konstanty ventilu

4.2 Odvození matematického modelu

Matematický model byl odvozen na základě bilančních rovnic. Bilance vycházely z následujícího schématického obrázku.



Obr. 4.5 Schématické znázornění reálné soustavy Amira DTS200

Princip bilance:

$$\mathbf{Vstup + Vznik = Výstup + Akumulace,} \quad (56)$$

Vstup do soustavy představují dvě čerpadla. V soustavě nedochází k žádnému vzniku bilancované hmoty, proto je vznik roven nule. Výstup ze soustavy představuje 5 ventilů. Jedná se tedy o soustavu se dvěma vstupy a 5 výstupy. Za akumulaci byla považována derivace objemu podle času. Byly provedeny tři bilance, pro každou nádrž jedna. Čímž byly získány tři bilanční rovnice:

$$\text{I.} \quad q_{1V} = q_1 + q_{12V} + \frac{dV_1}{dt} \quad (57)$$

$$\text{II.} \quad q_{12V} = q_2 + q_{23V} + \frac{dV_2}{dt} \quad (58)$$

$$\text{III.} \quad q_{23V} + q_{3V} = q_3 + \frac{dV_3}{dt} \quad (59)$$

Derivace objemu podle času lze rozepsat jako:

$$\frac{dV}{dt} = A \cdot \frac{dh}{dt}, \quad A = \pi \left(\frac{D^2}{4} - \frac{D_1^2}{4} \right) \quad (60)$$

Kde D představuje průměr podstavy nádrže a D_1 značí průměr otvoru v podstavě nádrže.

$$\begin{aligned}
 q_{12V} &= k_{12}\sqrt{h_1 - h_2} \\
 q_1 &= k_1\sqrt{h_1} \\
 q_2 &= k_2\sqrt{h_2} \\
 q_3 &= k_3\sqrt{h_3} \\
 q_{23V} &= k_{23}\sqrt{h_2 - h_3}
 \end{aligned}
 \tag{61}$$

Po dosazení do základních bilančních rovnic dostaneme:


$$\frac{dh_1}{dt} = \frac{q_{1V} - k_1\sqrt{h_1} - k_{12}\sqrt{h_1 - h_2}}{A}
 \tag{62}$$

$$\frac{dh_2}{dt} = \frac{k_{12}\sqrt{h_1 - h_2} - k_2\sqrt{h_2} - k_{23}\sqrt{h_2 - h_3}}{A}
 \tag{63}$$

$$\frac{dh_3}{dt} = \frac{k_{23}\sqrt{h_2 - h_3} + q_{3V} - k_3\sqrt{h_3}}{A}
 \tag{64}$$

4.2.1 Ustálený stav

Pro ustálený stav platí, že se derivace rovná nule. Pro ustálený stav byla zvolena následující konfigurace: čerpadlo Č1 bylo nastaveno na 40% svého výkonu a ventily V1 a V5 byly nastaveny na 50% otevření ostatní byly uzavřeny. Toto uspořádání a výběr hodnot parametrů bylo získáno po několika simulacích jako vhodná kombinace. Při vyšších hodnotách průtoku nebo menším otevření ventilu docházelo k překročení maximální výšky u hladiny T1.



Obr. 4.6 Konfigurace reálné soustavy pro měření ustáleného stavu

Rovnice pak mají tvar:

$$0 = \frac{q_{1v} - k_1\sqrt{h_1} - k_{12}\sqrt{h_1 - h_2}}{A} \quad (65)$$

$$0 = \frac{k_{12}\sqrt{h_1 - h_2} - k_2\sqrt{h_2} - k_{23}\sqrt{h_2 - h_3}}{A}$$

$$k_1 = 0 \quad k_{23} = 0 \quad (66)$$

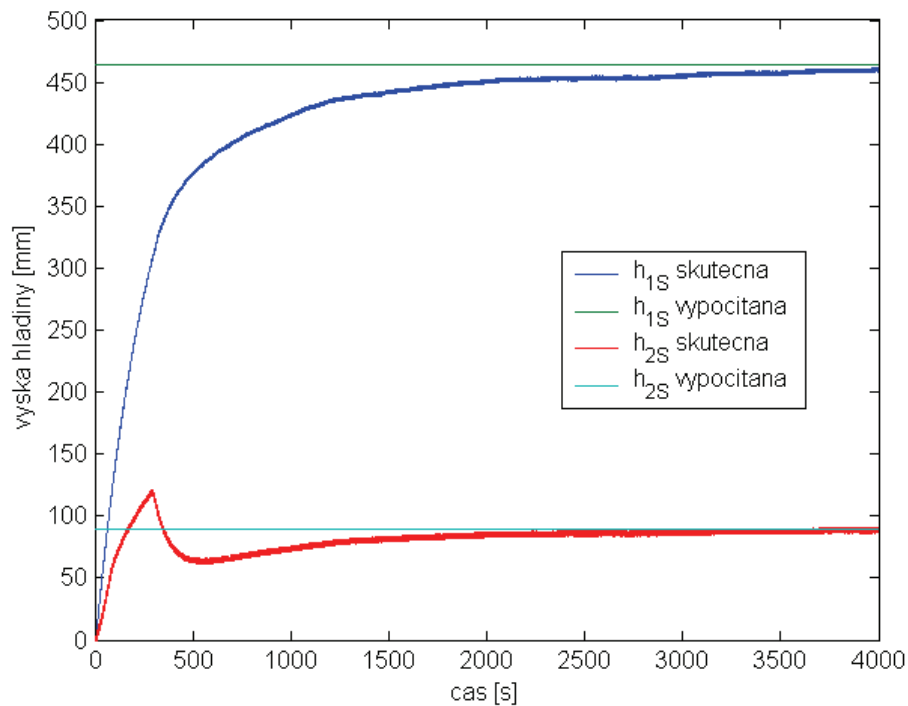
$$0 = \frac{q_{1v} - k_{12}\sqrt{h_1 - h_2}}{A} \quad (67)$$

$$0 = \frac{k_{12}\sqrt{h_1 - h_2} - k_2\sqrt{h_2}}{A}$$

$$h_1 = q_{1v}^2 \left(\frac{1}{k_2^2} + \frac{1}{k_{12}^2} \right) \quad (68)$$

$$h_2 = \frac{q_{1v}^2}{k_2^2}$$

$$\begin{aligned} k_{12} &= -0,15947 & k_2 &= -0,0983 & q_{1v} &= 2,9282 \\ h_{1s} &= \underline{464mm} & h_{2s} &= \underline{89mm} \end{aligned} \quad (69)$$



Obr. 4.7 Měření ustálených výšek hladin

Z grafu Obr. 4.7 je patrné, že výpočet byl proveden správně, neboť výška hladin se ustálila na vypočítaných výškách ustálených hladin. U průběhu výšky hladiny v nádrži T2 je kolem času 300s vidět náhlý pokles hladiny. Měření bylo provedeno několikrát a tento pokles se vždy objevil v podobném čase. Tento pokles mohl být zapříčiněn tím, že měřením začínalo s nulové výšky hladiny a ve ventilech při zahájení napouštění zůstaly vzduchové bubliny, které byly odstraněny až při určité výšce hladiny. Ostatní ventily podobný problém neměly.

4.2.2 Linearizace modelu

Nelineární část modelu představuje odmocnina. Linearizace modelu byla provedena v ustáleném bodě, který byl popsán v předcházející kapitole.

$$h_1(0) = h_1^s \quad h_2(0) = h_2^s \quad (70)$$

$$\begin{aligned} q_{12}^s &= k_{12} \sqrt{h_1^s - h_2^s} \\ q_2^s &= k_2 \sqrt{h_2^s} \end{aligned} \quad (71)$$

$$x_j(t) = \Delta h_j(t) = h_j(t) - h_j^s, \quad j = 1, 2 \quad (72)$$

$$u_j(t) = \Delta q_{jV}(t) = q_{jV}(t) - q_{jV}^s, \quad j = 1 \quad (73)$$

$$\frac{d\Delta h_1}{dt} = \frac{\Delta q_{1V} - \Delta q_{12}}{A} \quad (74)$$

$$\frac{d\Delta h_2}{dt} = \frac{\Delta q_{12} - \Delta q_2}{A} \quad (75)$$

$$\begin{aligned} \Delta q_{12} &\approx \left(\frac{\partial q_{12}}{\partial h_1} \right)^s \Delta h_1 + \left(\frac{\partial q_{12}}{\partial h_2} \right)^s \Delta h_2 = \frac{k_{12}}{2\sqrt{h_1^s - h_2^s}} \Delta h_1 - \frac{k_{12}}{2\sqrt{h_1^s - h_2^s}} \Delta h_2 = \\ &= \frac{k_{12}}{2\sqrt{h_1^s - h_2^s}} (\Delta h_1 - \Delta h_2) = \frac{k_{12} \sqrt{h_1^s - h_2^s}}{2(h_1^s - h_2^s)} (\Delta h_1 - \Delta h_2) = \frac{q_{12}^s}{2(h_1^s - h_2^s)} (\Delta h_1 - \Delta h_2) = (76) \\ &= \underline{\underline{C_1}} (\Delta h_1 - \Delta h_2) \end{aligned}$$

$$\begin{aligned} \Delta q_2 &\approx \left(\frac{\partial q_2}{\partial h_1} \right)^s \Delta h_1 + \left(\frac{\partial q_2}{\partial h_2} \right)^s \Delta h_2 = 0 \Delta h_1 + \frac{k_2}{2\sqrt{h_2^s}} \Delta h_2 = \frac{k_2 \sqrt{h_2^s}}{2h_2^s} \Delta h_2 = \\ &= \frac{q_2^s}{2h_2^s} \Delta h_2 = \underline{\underline{C_2}} \Delta h_2 \end{aligned} \quad (77)$$

$$\begin{aligned}
 A \frac{dx_1}{dt} &= u_1 - C_1(x_1 - x_2) \\
 A \frac{dx_2}{dt} &= C_1(x_1 - x_2) - k_2 x_2
 \end{aligned} \tag{78}$$

$$\begin{aligned}
 \frac{dx_1}{dt} &= a_{11}x_1 + a_{12}x_2 + b_{11}u_1 & a_{11} &= -\frac{C_1}{A}, & a_{12} &= \frac{C_1}{A} \\
 \frac{dx_2}{dt} &= a_{21}x_1 + a_{22}x_2 + b_{22} & a_{21} &= \frac{C_1}{A}, & a_{22} &= \frac{-C_1 - C_2}{A} \\
 & & b_{11} &= \frac{1}{A}, & b_{22} &= 0
 \end{aligned} \tag{79}$$

$$A = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \quad B = \begin{bmatrix} b_{11} \\ b_{22} \end{bmatrix} \quad C = [0 \quad 1] \quad U = [\Delta u] \tag{80}$$

$$Y = C(Is - A)^{-1} B \cdot U \tag{81}$$

$$\begin{aligned}
 Y &= [0 \quad 1] \left[\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} s - \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \right]^{-1} \begin{bmatrix} b_{11} \\ b_{22} \end{bmatrix} [\Delta u] \\
 Y &= [0 \quad 1] \left[\begin{bmatrix} s - a_{11} & -a_{12} \\ -a_{21} & s - a_{22} \end{bmatrix} \right]^{-1} \begin{bmatrix} b_{11} \\ b_{22} \end{bmatrix} [\Delta u] \\
 Y &= [0 \quad 1] \begin{bmatrix} \frac{s - a_{22}}{s^2 - (a_{11} + a_{22})s + a_{22}a_{11}} & \frac{a_{12}}{s^2 - (a_{11} + a_{22})s + a_{22}a_{11}} \\ \frac{a_{21}}{s^2 - (a_{11} + a_{22})s + a_{22}a_{11}} & \frac{s - a_{11}}{s^2 - (a_{11} + a_{22})s + a_{22}a_{11}} \end{bmatrix} \begin{bmatrix} b_{11} \\ b_{22} \end{bmatrix} [\Delta u]
 \end{aligned} \tag{82}$$

Linearizací byly získány dva přenosy:

$$\begin{aligned}
 G_{h1} &= \frac{b_2 s + b_1}{s^2 + a_1 s + a_2}, \\
 b_2 &= b_{11}, \quad b_1 = -b_{11}a_{22} + a_{12}b_{22} \\
 a_2 &= 1, \quad a_1 = -a_{11} - a_{22}, \quad a_0 = a_{11}a_{22} - a_{12}a_{21}
 \end{aligned} \tag{83}$$

$$\begin{aligned}
 G_{h2} &= \frac{b_2 s + b_1}{s^2 + a_1 s + a_2}, \\
 b_2 &= b_{22}, \quad b_1 = -b_{22}a_{11} + a_{21}b_{11} \\
 a_2 &= 1, \quad a_1 = -a_{11} - a_{22}, \quad a_0 = a_{11}a_{22} - a_{12}a_{21}
 \end{aligned} \tag{84}$$

4.3 Realizace matematického modelu v prostředí Matlab / Simulink

V předcházející kapitole byly odvozeny přenosy. Po dosazení konstant získáme jednotlivé členy k polynomům A a B . K těmto spojitým přenosům byly také vypočteny diskrétní přenosy. Perioda vzorkování byla zvolena vzhledem k dynamice systému $T = 5s$.

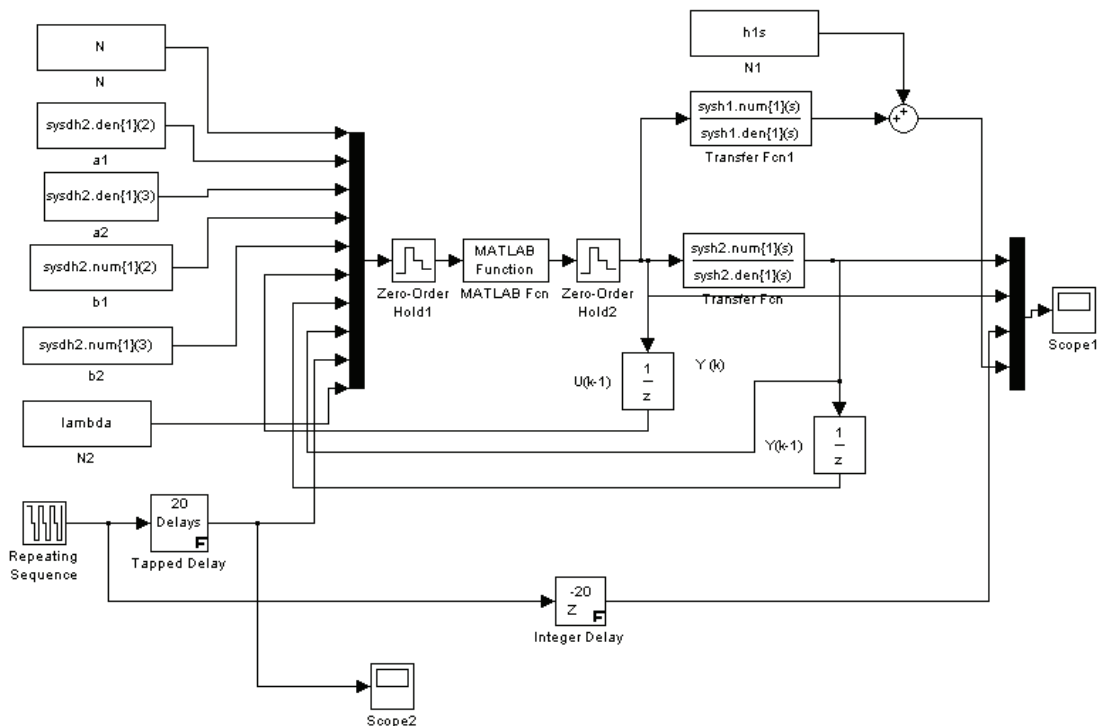
$$G_{h1}(s) = \frac{s + 0,009536}{s^2 + 0,01271s + 2,018e-005} \quad (85)$$

$$G_{h1}(z^{-1}) = \frac{4,961z^{-1} - 4,73z^{-2}}{1 - 1,938z^{-1} + 0,9384z^{-2}}$$

$$G_{h2}(s) = \frac{0.003171}{s^2 + 0,01271s + 2,018e-005} \quad (86)$$

$$G_{h2}(z^{-1}) = \frac{0.03881z^{-1} + 0.03799z^{-2}}{1 - 1,938z^{-1} + 0,9384z^{-2}}$$

Simulační schéma bylo vytvořeno v programovém prostředí MATLAB/Simulink a je znázorněno na Obr. 4.8.



Obr. 4.8 Simulační schéma pro matematický model `prediktor.mdl`

5 PREDIKTIVNÍ ŘÍZENÍ SOUSTAVY AMIRA DTS200

5.1 Návrh prediktivního regulačního algoritmu

Podrobné odvození prediktivního regulačního algoritmu je popsáno v kapitole 1.4. Prediktivní algoritmus byl realizován pomocí funkce v programu Matlab *quadprog*. Tato funkce řeší problém kvadratického programování. Aby bylo možné tuto funkci použít je potřeba převést kritérium, které má být minimalizováno, do tvaru

$$\min_x \frac{1}{2} x^T H x + f^T x \quad (87)$$

Výpočet matic H a f je odvozen v kapitole 1.4. Neznámou x v našem případě představuje matice budoucích hodnot U_p . Funkce *quadprog* umožňuje řadu nastavení např. Omezení akční veličiny. Toto nastavení se provádí pomocí parametrů LB a UB . LB představuje hodnotu maximálního akčního zásahu a UB hodnotu minimálního akčního zásahu. Zápis této funkce v programu MATLAB je:

$$X=QUADPROG(H,f,[],[],[],[],LB,UB). \quad (88)$$

Vektor X obsahuje vektor akčních zásahů. Délka vektoru má rozměr $N \times 1$, kde N představuje predikční horizont. Při regulaci je však zapotřebí vždy pouze první hodnota z vektoru X . Akční veličinu je také možno měnit pomocí parametru $lambda$. Platí, že čím je $lambda$ vyšší, tím je změna akčního zásahu menší tím pádem i přechody regulované veličiny jsou pomalejší a naopak. Např. při příliš vysoké hodnotě $lambda$ se akční veličina nemusí v čase vůbec změnit. Několika pokusy byla zvolena optimální velikost $lambda = 1000$. Stejně tak predikční horizont $N = 20$. Hodnota N představuje, kolik kroků dopředu bude regulátor predikovat hodnoty. Použitý krok (perioda vzorkování) byl 5s tedy predikční horizont je 100s.

Obsah funkce *predik.m* pro výpočet akčního zásahu

```
function [u]=predik(vstup)

N=vstup(1);
y_k=vstup(2);
y_k_1=vstup(3);
u_k_1=vstup(4);
W=vstup(4+1:4+N);
a0=1;
```

```

a1=vestup(4+N+1);
a2=vestup(4+N+2);
b1=vestup(4+N+3);
b2=vestup(4+N+4);
lambda=20;

A1=[0*eye(N,1) a1*eye(N,N+1)]+ a2*eye(N,N+2) + [0*eye(N,2) a0*eye(N,N)];
At=A1(:,1:2);
Ap=A1(:,3:end);

B1=[0*eye(N,1) b1*eye(N,N)]+ b2*eye(N,N+1);
Bt=B1(:,1);
Bp=B1(:,2:end);

R=[0*eye(N,1) 1*eye(N,N)]+ -1*eye(N,N+1);
Rt=R(:,1);
Rp=R(:,2:end);

Yt=[y_k_1;y_k];
Ut=[u_k_1];

Wm=W-inv(Ap) * (Bt*Ut-At*Yt);

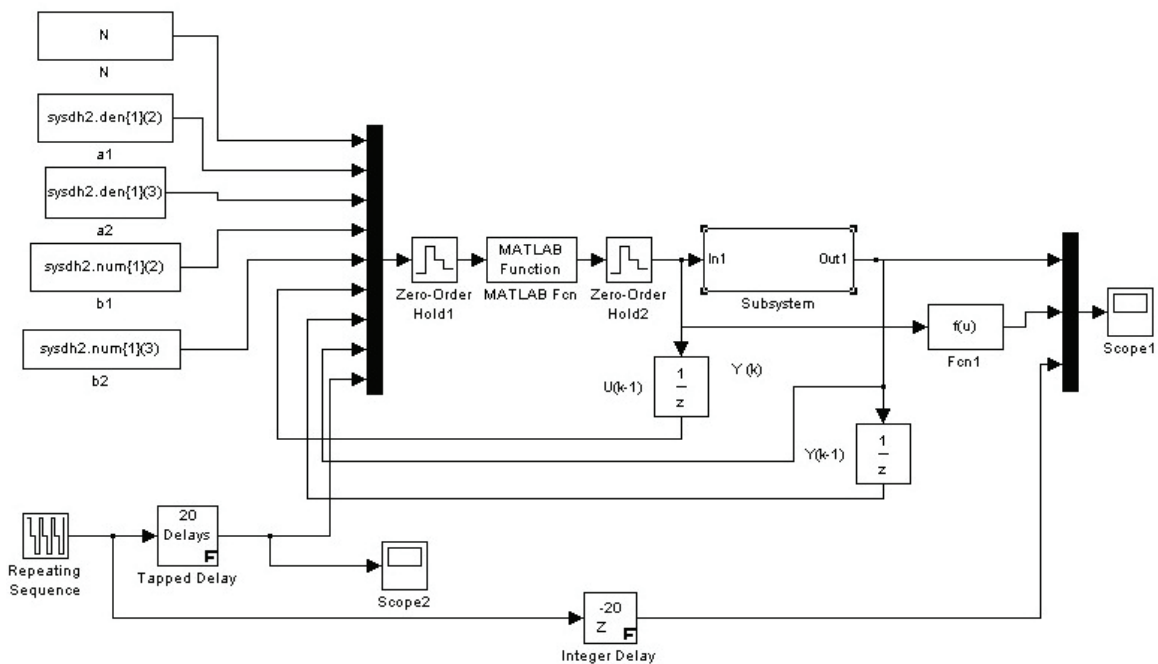
H1=Bp'*inv(Ap) *inv(Ap) *Bp;
f1=-Wm'*inv(Ap) *Bp;
H2=lambda*Rp'*Rp;
f2=lambda*Ut'*Rt'*Rp;

H=H1+H2;
f=f1+f2;
q1s=2.3787; %mm/s
LB=-q1s*ones(N,1); %min.prutok
qmax=6.2429; % [mm/s]
UB=(qmax-q1s)*ones(N,1); %mm/s
opt=optimset('quadprog');
opt=optimset(opt,'LargeScale','off', 'Display','off');
H=(H+H')/2;
X=QUADPROG(H,f,[],[],[],[],LB,UB,[],opt);
u=X;

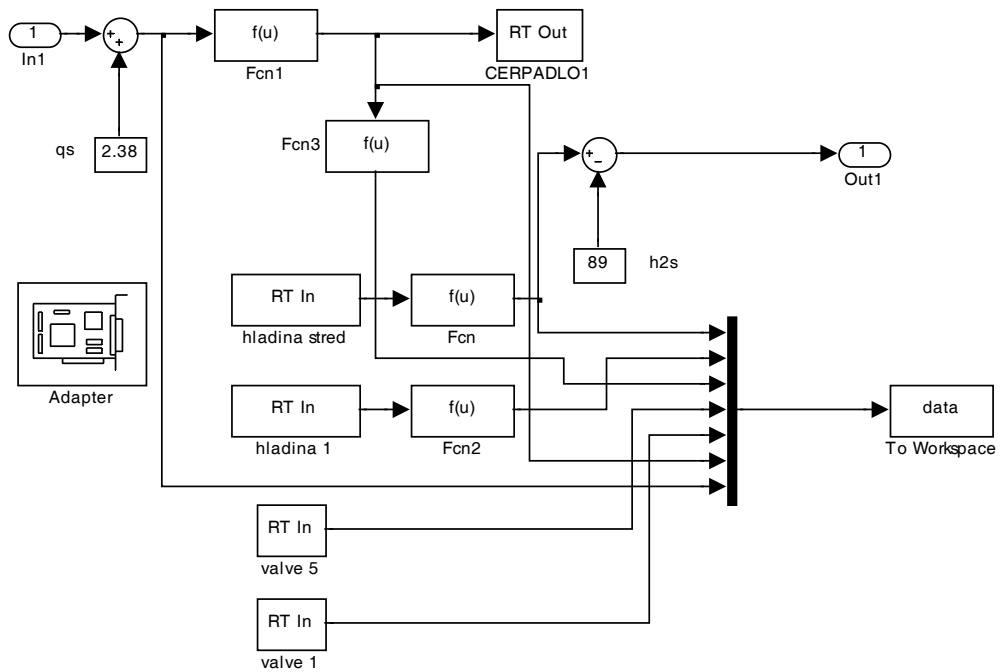
```

5.2 Porovnání vlastnosti regulačních pochodů pro různá nastavení prediktivního regulátoru


V této kapitole budou zobrazeny průběhy regulačních pochodů pro různá nastavení regulátoru. Při měřeních byly měněny parametry λ a N . Jak již bylo řečeno, matematický model byl získán linearizací v ustáleném bodě. Proto bylo nutné před vlastním měřením soustavu uvést do ustáleného stavu. Při měření ustáleného stavu se hladina ustálila za 4000s. Z důvodu časové tísně nebylo provedeno před každým měřením toto zdlouhavé ustalování, ale hladiny byly nastaveny ručně na přibližnou hodnotu ($\pm 5\text{cm}$). Měření pro různá nastavení parametrů byla vždy provedena dvakrát. Jednou z ustálené výšky hladiny a podruhé z nulové výšky hladiny. Na obrázcích Obr. 5.1 a Obr. 5.2 je zobrazeno simulační schéma z programu MATLAB/Simulink sloužící pro měření a regulaci na reálné soustavě. Perioda vzorkování byla pro všechna měření stejná a to 5s.



Obr. 5.1 Simulinkové schéma pro měření na reálném modelu
prediktor_real.mdl




Obr. 5.2 Obsah bloku Subsystem v simulinkovém schématu prediktor_real.mdl




Obr. 5.3 Regulační pochod z ustáleného stavu pro $\lambda = 10$, $N = 20$

Z tohoto měření je patrné, že regulovaná veličina kmitala kolem žádané veličiny. Hodnota parametru λ měla za následek příliš častý a velký rozsah akčních zásahů. Funkčnost

prediktivního řízení lze pozorovat z toho, že regulovaná veličina reaguje na skok žádané veličiny ještě dříve, než k němu dojde.




Obr. 5.4 Průběh akčního zásahu při měření z ustáleného stavu pro $\lambda = 10$, $N = 20$




Obr. 5.5 Regulační pochod z nulové hladiny pro $\lambda = 10$, $N = 20$

I při regulaci z nulové výšky hladiny (výrazná změna od ustáleného stavu) byla regulace úspěšná. Náhle strmý pokles hladiny v čase 500s mohl být zapříčiněn vzduchovou bublinou, jak již bylo zmíněno v předcházející kapitole.




Obr. 5.6 Průběh akčního zásahu při měření z nulové hladiny pro $\lambda = 10$, $N = 20$




Obr. 5.7 Regulační pochod z ustáleného stavu pro $\lambda = 1000$, $N = 20$

Vyšší hodnota λ napomohla ke kvalitnější regulaci. Bylo dosaženo mírnějších akčních zásahů a menší regulační odchylky.




Obr. 5.8 Regulační pochod z nulové hladiny pro $\lambda = 1000$, $N = 20$

Během tohoto měření z nulové výšky hladiny bylo dosaženo trvalé regulační odchylky.




Obr. 5.9 Regulační pochod z ustáleného stavu pro $\lambda = 100000$, $N = 20$

Vysoká hodnota λ měla za následek velmi malé a pomalé změny akční veličiny, což vedlo k neustálení hladiny na žádané výšce.




Obr. 5.10 Regulační pochod z nulové hladiny pro $\lambda = 100000$, $N = 20$

Zde jde vidět stejný průběh, i když je start z nulové hladiny, jako u Obr. 5.9.



Obr. 5.11 Regulační pochod z ustáleného stavu pro $\lambda = 1000$, $N = 10$

Menší hodnota prediktivní horizontu (50s) měla za následek rozkmitání a neustálení výšky hladiny na žádané hodnotě. Regulátor neměl dostatek informací o průběhu.



Obr. 5.12 Regulační pochod z ustáleného stavu pro $\lambda = 1000$, $N = 30$

Regulační pochod je podobný jako při nastavení $N = 20$. S tím rozdílem, že se výška hladiny ustálila mírně pod žádanou hladinou tedy s trvalou regulační odchylkou.

Měření byla hodnocena podle kritéria založeného na výpočtu sumace kvadrátů regulační odchylky $e(k) = w(k) - y(k)$ a přírůstků akční veličiny $\Delta u(k) = u(k) - u(k-1)$ podle vztahů

$$S_y = \frac{1}{k_2 - k_1 + 1} \sum_{k=k_1}^{k_2} e^2(k); \quad S_u = \frac{1}{k_2 - k_1 + 1} \sum_{k=k_1}^{k_2} \Delta u^2(k) \quad (89)$$

kde $\langle k_1, k_2 \rangle$ je zvolený interval pro určení kvality regulace. Byl zvolen interval celého rozsahu měření.

Tab. 5.1 Vyhodnocení kvality regulace pro měření z nulové výšky hladiny

λ	N	S_y	S_u
10	20	27,1892	1,8185
1000	20	25,9102	0,0601
100000	20	139,449	3,22E-04



Tab. 5.2 Vyhodnocení kvality regulace pro měření z ustálené výšky hladiny


λ	N	S_y	S_u
10	20	1,6674	2,1179
1000	20	1,3363	0,0575
100000	20	10,8156	4,50E-05
1000	10	15,9843	0,0072
1000	30	2,2245	0,0604

Z uvedených tabulek vyplývá, že nejkvalitnější měření z hlediska kritéria S_y bylo s parametry $\lambda = 1000$, $N = 20$ a nejkvalitnější měření z hlediska kritéria S_u bylo s parametry $\lambda = 100000$, $N = 20$. Což potvrdilo fakt, že při velké hodnotě parametru λ dochází k velmi malým změnám akční veličiny; negativním vlivem je ale nekvalitní regulace. Na kvalitu regulace mělo také vliv, zda měření začíná s ustálené nebo nulové výšky hladiny.

5.3 Porovnání regulačních pochodů simulinkovém modelu a reálné soustavy Amira DTS200

Porovnání bylo provedeno pouze pro jedno nastavení parametrů a sice pro parametry $\lambda = 1000$, $N = 20$ z důvodu dobré kvality regulace S_y . Z obrázků Obr. 5.13 a Obr. 5.14 je patrná shoda simulace a reálného měření, i když je měření značně zatíženo šumem. Z toho plyne, že byl matematický model vytvořen správně.


 Obr. 5.13 Simulace z ustáleného stavu pro $\lambda = 1000$, $N = 20$

 Obr. 5.14 Regulační pochod z ustáleného stavu pro $\lambda = 1000$, $N = 20$



Obr. 5.15 Porovnání regulačního a simulačního pochodu pro $\lambda = 1000$, $N = 20$

Výstup soustavy byl ovlivněn aditivním šumem, který měl charakteristiku bílého šumu, a po simulaci byla data porovnána v jednom grafu s naměřeným daty. I v tomto případě je vidět shoda průběhu jak regulované veličiny tak i akční veličiny.

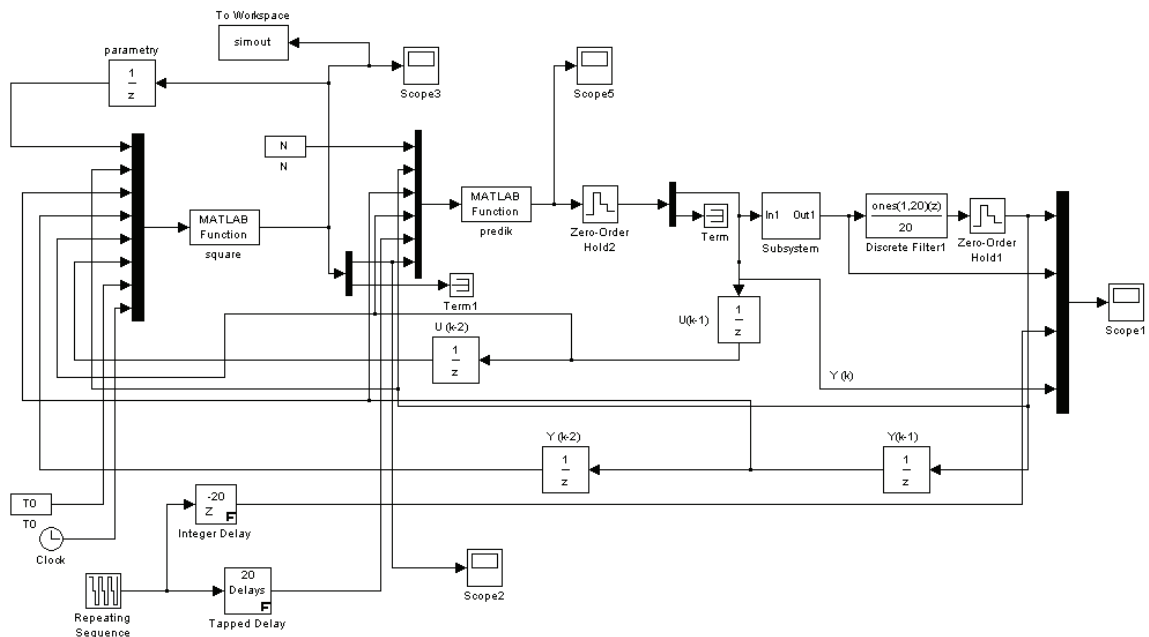
Tab. 5.3 Vyhodnocení kvality regulace pro porovnání regulačního a simulačního pochodu

	λ	N	S_y	S_u
simulace bez šumu	1000	20	0,8631	5,13E-04
reálné měření	1000	20	1,3363	0,0575
simulace se šumem	1000	20	0,8788	0,0021

5.4 Online identifikace

V dalším měření byla do regulačního obvodu zařazena online identifikace pomocí rekurzivní metody nejmenších čtverců, která je teoreticky popsána v kapitole 2.3. Pro nově vypočtené parametry soustavy je v každém kroku počítán nový akční zásah. Jako počáteční

odhady parametrů byly zvoleny parametry získané z identifikace soustavy pomocí matematického modelu. Na tuto regulaci mají velký vliv hodnoty na hlavní diagonále kovarianční matice C . Čím jsou hodnoty na hlavní diagonále kovarianční matice (dále označené jako c) vyšší tím mají počáteční parametry menší váhu a naopak. Udává důvěryhodnost počátečních a předcházejících parametrů. Nastavení parametrů $\lambda = 1000$, $N = 20$ bylo zvoleno z důvodu dobré kvality regulace S_y . Při měření byl použit filtr regulované veličiny, neboť metoda RMNČ měla velké problémy se šumem na výstupu z reálné soustavy. Použit byl filtr e tvaru klouzavého průměru. Data pro filtr byla vzorkována s periodou 0,1s a průměr byl vypočten z posledních 20 hodnot. Tento průměr byl výstupem po dobu periody vzorkování pro měření tedy 5s. Na obrázku Obr. 5.17 můžete vidět rozdíl mezi filtrovanou a nefiltrovanou regulovanou veličinou.



Obr. 5.16 Schéma pro online identifikaci `prediktor_real_ctverce.mdl`


Obsah funkce `square.m` pro výpočet nových parametrů

```
function [prenos]=square(vstup)


sigma_stare=vstup(1:4);
C_stare=0.1*eye(4);
C_stare(:)=vstup(4+1:4+16);
y_k=vstup(4+16+1);
y_k_1=vstup(4+16+2);
y_k_2=vstup(4+16+3);
u_k_1=vstup(4+16+4);
```

```
u_k_2=vstup(4+16+5);


fi(1,1)=-y_k_1;
fi(2,1)=-y_k_2;
fi(3,1)=u_k_1;
fi(4,1)=u_k_2;
ee=y_k-sigma_stare'*fi;
C_nove=C_stare-((C_stare*fi*fi'*C_stare)/(1+fi'*C_stare*fi));
C_stare=C_nove;
sigma_nove=sigma_stare+(ee*((C_stare*fi)/(1+fi'*C_stare*fi)));
sigma_stare=sigma_nove;
alp=sigma_nove(1); a2p=sigma_nove(2); b1p=sigma_nove(3); b2p=sigma_nove(4);
prenos=[alp;a2p;b1p;b2p];
prenos=[prenos, C_stare];
```




Obr. 5.17 Porovnání filtrované a nefiltrované regulační veličiny




Obr. 5.18 Regulační pochod při online identifikaci, $\lambda = 1000$, $N = 20$, $c = 0,1$



Obr. 5.19 Průběh identifikace parametrů modelu pro $\lambda = 1000$, $N = 20$, $c = 0,1$



Obr. 5.20 Regulační pochod při online identifikaci, $\lambda = 1000$, $N = 20$, $c = 1e-10$



Obr. 5.21 Průběh identifikace parametrů modelu pro $\lambda = 1000$, $N = 20$, $c = 1e-10$

Při měření byla prodloužena doba mezi jednotlivými skoky žádané veličiny o 200s. Při kratších časech se jednak nestihla ustálit regulovaná veličina a také průběh vývoje parametrů nebyl uspokojivý. Z naměřených dat a vykreslených grafů je patrné, že pro vyšší hodnoty kovarianční matice jsou parametry pro metodu RMNČ méně věrohodné a jsou v průběhu měření neustále zlepšovány. Při nízké hodnotě kovarianční matice prakticky ani vývoj parametrů neproběhl.

Tab. 5.4 Vyhodnocení kvality regulace pro různé nastavení c

c	λ	N	S_y	S_u
1,00E-01	1000	20	1703,5	2,14E+01
1,00E-10	1000	20	167,5973	17,0891

ZÁVĚR

Cílem této diplomové práce bylo porovnání simulace a reálného měření pomocí prediktivního řízení hladin ve spojených nádržích na reálné soustavě Amira DTS200. Aby mohla být porovnána simulace a měření, bylo nejprve nutné vytvořit model reálné soustavy. Model byl vytvořen na základě matematicko-fyzikální analýzy a rovnice vycházely z matematické bilance. Byly získány diferenciální rovnice, které v sobě obsahovaly nelineární člen. Proto byla nutná linearizace. Linearizace byla provedena v bodě ustáleného stavu. Výsledný linearizovaný model byl realizován v programovém prostředí Matlab / Simulink. Dalším úkolem byl návrh prediktivního algoritmu pomocí metody ustupujícího horizontu. Pro takto navržený regulátor bylo provedeno několik měření pro různá nastavení prediktivního regulátoru. Z dosažených měření lze usoudit, že nižší hodnota parametru λ měla za následek velmi časté a vysoké změny akčního zásahu. Naopak při vyšších hodnotách λ byl průběh akčního zásahu klidnější a v menším rozsahu, což ale vedlo k neustálení hladiny na požadované výšce. Jako optimální se hodnota z hlediska kvality regulace se zdála být $\lambda = 1000$. Dalším parametrem, který se dal před měřením změnit, byl horizont řízení N . Při menší hodnotě měl regulátor málo informací o průběhu žádané a regulované veličiny, což mělo za následek rozkmitání a neustálení regulované veličiny. Při vyšší hodnotě N už byl průběh klidnější s ustálením na žádané hodnotě. Jako nejvhodnější kombinace parametrů se zdálo být z hlediska kvality regulace S_y nastavení $\lambda = 1000$ a $N = 20$. Měření byla hodnocena podle kritéria založeného na výpočtu sumace kvadrátů regulační odchylky a přírůstků akční veličiny. Po naměření možných kombinací parametrů byla data porovnána se simulačním průběhem. Toto porovnání je na Obr. 5.15 a lze z něj pozorovat velmi podobný průběh jak regulované veličiny tak i akční veličiny. V posledním měření byla do regulačního obvodu zařazena online identifikace pomocí rekurzivní metody nejmenších čtverců. Jako počáteční odhady parametrů byly zvoleny vypočtené parametry z linearizovaného modelu. Regulace s identifikací byla úspěšná až pro nižší hodnoty na hlavní diagonále kovarianční matice. Což ale také mělo za následek velmi slabý vývoj parametrů soustavy.

CONCLUSION

The aim of this master thesis was to compare simulations and real measurements using predictive control of levels in the tanks of the real system Amira DTS200. To compare simulation and measurement, it was first necessary to create a model of real system. The model was created on the basis of mathematical and physical analysis of the system based on the balance sheet. The system is described by differential equations, which contain a non-linear member. Therefore, there is the need for linearization. Linearization was carried out in steady state. The resulting linearized model was implemented in the programming environment Matlab / Simulink. Another challenge was to design a predictive algorithm using the receding horizon method. Several measurements for different settings of proposed predictive controller were made. The measurements confirmed that the lower value of λ results in very high and frequent changes in control input. On the other hand, for the higher values of λ the course of control sequence was slower and smoother but this led to nonzero control error in the steady states. As the best value in terms of quality of the control appeared to be $\lambda = 1000$. Other parameter, which affected the control courses, was control horizon N . With the smaller value of N the controller did not have enough information about the course of reference signal and controlled output which resulted in oscillations and instability of controlled output. The higher value of N resulted in smoother tracking of the reference signal. The most appropriate combination of parameters seemed to be – in terms of quality of the control – settings $\lambda = 1000$ and $N = 20$. Measurements were evaluated according to criteria based on summing squares of tracking error and squares of control signal differences. After measurement of combinations of parameters, data was compared with the simulated courses. This comparison is presented in Fig. 4.23 and a very similar course of both controlled output and control signal can be seen. In the last measurement, online identification method using recursive least squares was incorporated into the control circuit. The initial estimates of the parameters of the system were chosen as the parameters of the linearized model. Control with identification has been more successful for lower values on the main diagonal of covariance matrix. That also resulted in very small development of parameters of the system.

SEZNAM POUŽITÉ LITERATURY

- [1] Bobál, V.: *Teorie automatického řízení III.*. Skriptum FAI UTB, Zlín 2007.
- [2] Kwon, W.H., Han S.: *Receding Horizon Control*. Springer-Verlag, London, 2005. 380 s. ISBN 1846280249.
- [3] Bobál, V. *Identifikace systémů*. Vysoké učení technické v Brně. 1990.
- [4] Blaha, A., Janáčková, D.: *Procesní inženýrství I, II pro kombinované*, Skriptum FT UTB, Zlín 2005.
- [5] Bobál, V., J. Böhm, J. Fessl and J. Macháček.: *Digital Self-tuning Controllers: Algorithms, Implementation and Applications*. Springer. 2005. ISBN 1852339802
- [6] Kamler, R.: *Metody Identifikace Spojitých Modelů Technologických Soustav*. Skriptum FM TUL, Liberec 1999.
- [7] Qin, S. J., Badgwell, T. A.: *A survey of industrial model predictive control technology* [online]. 2003 [cit 2008-01-28]. Dostupné z URL http://cepac.cheme.cmu.edu/pasilectures/darciodolak/Review_article_2.pdf.
- [8] *Metoda nejmenších čtverců* [online]. [cit. 2008-01-28]. Dostupné z URL http://alpha.ujep.cz/~mlisal/nm_1/jskvor/PDF/AproxMNC.pdf
- [9] Camacho, E. F.: *Model predictive control*. London : Springer. 2004. 405 s. ISBN 1852336943.
- [10] *DTS200 Laboratory Setup Three - Tank - System*. Duisburg: Amira GmbH. 2002. 270s.

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

A	Matice polynomů A .
A	Polynom jmenovatele přenosu.
a_i	Konstanty polynomu A .
B	Matice polynomů B .
B	Polynom čitatele přenosu.
b_j	Konstanty polynomu B .
$C(k)$	Kovarianční matice odhadovaných parametrů.
du	Změna akční veličiny.
DMC	Dynamic Matrix Control.
Δu	Vektor budoucích diferencí akčního zásahu.
E	Matice hodnot regulačních odchylek.
E^T	Transponovaná matice E .
e	Regulační odchylka.
$\hat{e}(k)$	Vektor predikovaných regulačních odchylek.
$e_s(k)$	Bílý šum.
FIR	Finite impulse response.
$\phi(k)$	Regresní vektor (vektor dat).
G_{h1}	Spojité přenos pro nádrž T1.
G_{h2}	Spojité přenos pro nádrž T2.
G_{dh1}	Diskrétní přenos pro nádrž T1.
G_{dh2}	Diskrétní přenos pro nádrž T2.
g_i	Koeficienty impulsní odezvy.

GPC	Generalized Predictive Control.
$H(z^{-1})$	Lineární filtr.
$H(q^{-1})$	Polynom N – tého stupně.
h_1	Výška hladiny v nádrži T1.
h_2	Výška hladiny v nádrži T2.
h_3	Výška hladiny v nádrži T3.
h_j^s	Ustálená výška hladiny.
I	Jednotková matice.
J	Kritérium pro minimalizaci.
k	Charakteristická konstanta ventilu.
$L(k)$	Matice zesílení.
λ	Nastavitelný parametr lambda.
MAC	Model Algorithmic Control.
MPC	Model Predictive Control.
MPHC	Model Predictive Heuristic Control.
N	Počet budoucích výstupů procesu.
$n(k)$	Náhodný “barevný” šum.
Q	Váhová čtvercová matice.
q^{-1}	Operátor zpětného posuvu.
R	Váhová čtvercová matice.
r	Poloměr.
s	Komplexní proměnná.
$\hat{\Theta}(k)$	Vektor odhadovaných parametrů.

U	Matice akčních zásahů.
U_t	Matice akčních zásahů, které již není možné ovlivnit.
U_p	Matice ovlivnitelných akčních zásahů.
W	Matice žádaných hodnot.
Y	Matice hodnot regulační veličiny.
Y_t	Matice hodnot regulační veličiny, které již není možné ovlivnit.
Y_p	Matice ovlivnitelných hodnot regulační veličiny.

SEZNAM OBRÁZKŮ

Obr. 1.1 Podrobné blokové schéma stochastického modelu	13
Obr. 1.2 Základní struktura systému prediktivního řízení.....	15
Obr. 1.3 Princip prediktivního řízení ($N1$, $N2$, Nu – minimální, maximální, výhled řízení)	16
Obr. 4.1 Reálná soustava Amira DTS200.....	28
Obr. 4.2 Závislost napětí na senzoru na výšce hladiny.....	29
Obr. 4.3 Závislost změny výšky hladiny [mm/s] na výkonu čerpadla Č1 [%].....	30
Obr. 4.4 Závislost pozice ventilu na hodnotě konstanty ventilu.....	31
Obr. 4.5 Schématické znázornění reálné soustavy Amira DTS200.....	32
Obr. 4.6 Konfigurace reálné soustavy pro měření ustáleného stavu	33
Obr. 4.7 Měření ustálených výšek hladin	34
Obr. 4.8 Simulační schéma pro matematický model <code>prediktor.mdl</code>	37
Obr. 5.1 Simulinkové schéma pro měření na reálném modelu <code>prediktor_real.mdl</code>	40
Obr. 5.2 Obsah bloku <code>Subsystem</code> v simulinkovém schématu <code>prediktor_real.mdl</code>	41
Obr. 5.3 Regulační pochod z ustáleného stavu pro $\lambda = 10$, $N = 20$	41
Obr. 5.4 Průběh akčního zásahu při měření z ustáleného stavu pro $\lambda = 10$, $N = 20$	42
Obr. 5.5 Regulační pochod z nulové hladiny pro $\lambda = 10$, $N = 20$	42
Obr. 5.6 Průběh akčního zásahu při měření z nulové hladiny pro $\lambda = 10$, $N = 20$	43
Obr. 5.7 Regulační pochod z ustáleného stavu pro $\lambda = 1000$, $N = 20$	43
Obr. 5.8 Regulační pochod z nulové hladiny pro $\lambda = 1000$, $N = 20$	44
Obr. 5.9 Regulační pochod z ustáleného stavu pro $\lambda = 100000$, $N = 20$	44
Obr. 5.10 Regulační pochod z nulové hladiny pro $\lambda = 100000$, $N = 20$	45
Obr. 5.11 Regulační pochod z ustáleného stavu pro $\lambda = 1000$, $N = 10$	45
Obr. 5.12 Regulační pochod z ustáleného stavu pro $\lambda = 1000$, $N = 30$	46
Obr. 5.13 Simulace z ustáleného stavu pro $\lambda = 1000$, $N = 20$	48
Obr. 5.14 Regulační pochod z ustáleného stavu pro $\lambda = 1000$, $N = 20$	48
Obr. 5.15 Porovnání regulačního a simulačního pochodu pro $\lambda = 1000$, $N = 20$	49
Obr. 5.16 Schéma pro online identifikaci <code>prediktor_real_ctverce.mdl</code>	50

Obr. 5.17 Porovnání filtrované a nefiltrované regulační veličiny	51
Obr. 5.18 Regulační pochod při online identifikaci, $\lambda = 1000$, $N = 20$, $c = 0,1$	52
Obr. 5.19 Průběh identifikace parametrů modelu pro $\lambda = 1000$, $N = 20$, $c = 0,1$	52
Obr. 5.20 Regulační pochod při online identifikaci, $\lambda = 1000$, $N = 20$, $c = 1e-$ 10	53
Obr. 5.21 Průběh identifikace parametrů modelu pro $\lambda = 1000$, $N = 20$, $c = 1e-$ 10	53

SEZNAM TABULEK

Tab. 1.1 Klasifikace lineárních stochastických modelů	13
Tab. 2.1 Shrnutí vlastností "White box" a "Black box" modelu.....	23
Tab. 4.1 Napětí jdoucí z ventilů na analogovou kartu	29
Tab. 4.2 Napětí jdoucí z nádrží na analogovou kartu	29
Tab. 4.3 Napětí jdoucí z čerpadel na analogovou kartu	29
Tab. 5.1 Vyhodnocení kvality regulace pro měření z nulové výšky hladiny	46
Tab. 5.2 Vyhodnocení kvality regulace pro měření z ustálené výšky hladiny	47
Tab. 5.3 Vyhodnocení kvality regulace pro porovnání regulačního a simulačního pochodu	49
Tab. 5.4 Vyhodnocení kvality regulace pro různé nastavení c	54

SEZNAM PŘÍLOH

P1 – CD ROM

PŘÍLOHA P1: CD ROM

Obsahuje tyto adresáře:

„DIPLOMOVÁ PRÁCE“ – diplomová práce ve formátu pdf

„SIMULAČNÍ SCHÉMATA“ – prediktor_real_ctverce, prediktor, prediktor_real, prediktor_real_ctverce_filtr ve formátu mdl, m-file soubory nutné k rozjetí simulačních schématů prenos_start.m, square.m, predik.m.

„NAMĚŘENÁ DATA“ – soubory *.mat získané z měření na reálném systému Amira DTS200.