

Disertační práce

**Metody průběžné identifikace pro návrh
samočinně se nastavujících regulátorů**

Ing. Petr Navrátil

Školitel: prof. Ing. Vladimír Bobál, CSc.

Univerzita Tomáše Bati ve Zlíně

Fakulta aplikované informatiky

Ústav řízení procesů

Zlín, 2007

Poděkování:

Je pro mne milou povinností poděkovat svému školiteli prof. Ing. Vladimíru Bobálovi, CSc. za odborné vedení během celého studia v rámci doktorského studijního programu.

Poděkování patří také všem mým blízkým, kteří se mnou měli dostatek trpělivosti v době, kdy jsem dokončoval tuto práci.

RESUMÉ

Navrátil P.: Metody průběžné identifikace pro návrh samočinně se nastavujících regulátorů

Školitel - prof. Ing. Vladimír Bobál, CSc., UTB ve Zlíně, Fakulta aplikované informatiky, 2007, 119 stran

Práce se zabývá jednou z možností zlepšení spolehlivosti a výkonu samočinně se nastavujícího regulátoru. Jednoduché rekurzivní identifikační schéma je nahrazeno složitější strukturou, založenou na paralelním běhu vybraných rekurzivních identifikačních algoritmů a jim odpovídajících adaptivních regulátorů. Nadřazený člen pak na základě vhodného kritéria vybírá v reálném čase nejvhodnější dvojici estimátor-regulátor. Základní užitečnost této struktury spočívá ve zvýšení přesnosti odhadů parametrů, což vede ke zlepšení přechodového děje v průběhu regulačního pochodu.

SUMMARY

Navrátil P.: Recursive identification methods for self-tuning controller

Supervisor - prof. Ing. Vladimír Bobál, CSc., UTB in Zlin, Faculty of Applied Informatics, 2007, 119 pages

This work deals with a one possibility of improvement of a self-tuning controller reliability and performance. A simple estimation scheme is replaced by so-called a multiestimation scheme and the self-tuning controller is then synthesized from this scheme. The scheme contains the supervisor which chooses the active controller and determined the switching time between controllers. The basic usefulness of the proposed scheme is to improve the accuracy of estimated parameters of the controlled system and then better transient response is obtained.

OBSAH

SEZNAM OBRÁZKŮ.....	7
SEZNAM TABULEK	9
SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK.....	10
1 ÚVOD.....	15
2 LITERÁRNÍ REŠERŠE.....	17
3 CÍLE DISERTAČNÍ PRÁCE	23
4 TYPY MODELŮ.....	24
5 KVALITA IDENTIFIKACE	28
6 STOCHASTICKÉ METODY IDENTIFIKACE	31
6.1 REGRESNÍ METODY.....	31
6.1.1 Požadavky na odhad parametrů	31
6.1.2 Identifikace dynamických systémů pomocí metody nejmenších čtverců.....	32
6.2 REKURZIVNÍ METODY IDENTIFIKACE	36
6.2.1 Rekurzivní metoda nejmenších čtverců (RLS).....	36
6.2.2 Modifikace základní rekurzivní metody nejmenších čtverců.....	40
6.2.3 Rekurzivní metoda instrumentální proměnné (RIV).....	45
6.2.4 Rozšířená rekurzivní metoda instrumentální proměnné (ERIV)	47
6.2.5 Rozšířená rekurzivní metoda nejmenších čtverců (RELS)	48
6.2.6 Rekurzivní metoda predikčních chyb (RPEM).....	50
6.3 INICIALIZACE REKURZIVNÍHO ALGORITMU	57
6.3.1 Volba počátečních odhadů vektoru parametrů	57
6.3.2 Počáteční nastavení kovarianční matice.....	57
6.3.3 Volba faktoru zapomínání.....	57
7 ADAPTIVNÍ ŘÍZENÍ.....	58
7.1 SAMOČINNĚ SE NASTAVUJÍCÍ REGULÁTORY (STC).....	58
7.1.1 Algoritmy identifikace pro samočinně se nastavující regulátory.....	60
8 PARALELNÍ ZAPOJENÍ REKURZIVNÍCH IDENTIFIKAČNÍCH ALGORITMŮ	61

8.1	NADŘAZENÝ ČLEN	63
8.1.1	<i>Start adaptivního regulátoru</i>	64
8.1.2	<i>Monitorování odhadu parametrů</i>	65
8.1.3	<i>Monitorování návrhu regulátoru</i>	69
8.1.4	<i>Volba aktivního regulátoru</i>	72
9	SIMULAČNÍ OVĚŘENÍ	75
9.1	POPIS INTEGROVANÉHO VÝVOJOVÉHO PROSTŘEDÍ MATLAB A SIMULINK	75
9.2	MODEL PRO SIMULAČNÍ OVĚŘOVÁNÍ	77
9.3	VÝSLEDKY SIMULAČNÍHO OVĚŘOVÁNÍ	80
9.3.1	<i>ME Schéma se sledováním průběhu chyby predikce</i>	80
9.3.2	<i>ME Schéma bez sledování průběhu chyby predikce</i>	82
9.3.3	<i>Adaptivní řízení s jednoduchým samočinně se nastavujícím regulátorem</i>	84
9.4	ROZBOR VÝSLEDKŮ	85
9.4.1	<i>Porovnání jednotlivých metod</i>	85
9.4.2	<i>Vyhodnocení jednotlivých metod</i>	86
10	EXPERIMENTÁLNÍ OVĚŘENÍ NA REÁLNÉM MODELU	88
10.1	POPIS LABORATORNÍHO MODELU	88
10.1.1	<i>Připojení modelu k PC</i>	89
10.2	POPIS REAL TIME TOOLBOX	89
10.3	VÝSLEDKY OVĚŘOVÁNÍ NA LABORATORNÍM MODELU	90
10.3.1	<i>ME Schema bez sledováním průběhu chyby predikce</i>	91
10.3.2	<i>Adaptivní řízení s jednoduchým samočinně se nastavujícím regulátorem</i> ..	93
10.4	ROZBOR VÝSLEDKŮ	95
10.4.1	<i>Vyhodnocení jednotlivých metod</i>	95
11	ZÁVĚR	97
	LITERATURA	99
	PUBLIKAČNÍ AKTIVITY	104
	KONFERENČNÍ PŘÍSPĚVKY	104
	PŘÍSPĚVKY V DOMÁCÍCH A ZAHRANIČNÍCH ČASOPISECH	105
	ODBORNÝ ŽIVOTOPIS AUTORA – CURRICULUM VITAE	107
	PŘÍLOHA A	108

A.1.	STRUČNÝ POPIS VYTVOŘENÉHO PROGRAMOVÉHO VYBAVENÍ ...	108
A.2.	STRUČNÝ POPIS KNIHOVNY REKURZIVNÍCH IDENTIFIKAČNÍCH ALGORITMŮ - RIA.....	118

SEZNAM OBRÁZKŮ

OBR. 4.1: PŘEHLED BĚŽNÝCH LINEÁRNÍCH DYNAMICKÝCH MODELŮ	26
OBR. 5.1: CHYBA VÝSTUPU	28
OBR. 5.2: CHYBA VSTUPU.....	29
OBR. 5.3: CHYBA ROVNICE.....	29
OBR. 6.1: BLOKOVÉ SCHÉMA DISKRÉTNÍHO SYSTÉMU	32
OBR. 7.1: ALGORITMICKÁ STRUKTURA SAMOČINNĚ SE NASTAVUJÍCÍHO REGULÁTORU	59
OBR. 8.1: PARALELNÍ MULTIESTIMAČNÍ SCHÉMA	61
OBR. 8.2: BLOKOVÉ SCHÉMA REGULAČNÍHO OBVODU S REGULÁTOREM SE DVĚMA STUPNI VOLNOSTI	69
OBR. 9.1: BLOKOVÉ SCHÉMA ŘÍZENÉHO SYSTÉMU	77
OBR. 9.2: ADAPTIVNÍ ŘÍZENÍ: MULTIESTIMAČNÍ SCHÉMA	81
OBR. 9.3: SEKVENCE PŘEPÍNÁNÍ	82
OBR. 9.4: ADAPTIVNÍ ŘÍZENÍ: MULTIESTIMAČNÍ SCHÉMA	83
OBR. 9.5: SEKVENCE PŘEPÍNÁNÍ	84
OBR. 9.6: ADAPTIVNÍ ŘÍZENÍ: JEDNODUCHÝ SAMOČINNĚ SE NASTAVUJÍCÍ REGULÁTOR	85
OBR. 10.1: LABORATORNÍ MODEL DTS200 – TŘI NÁDRŽE	88
OBR. 10.2: SCHÉMA LABORATORNÍHO MODELU DTS200 – TŘÍ NÁDRŽÍ	89
OBR. 10.3: STATICKÁ CHARAKTERISTIKA LABORATORNÍHO MODELU DTS200.....	90
OBR. 10.4: ADAPTIVNÍ ŘÍZENÍ: MULTIESTIMAČNÍ SCHÉMA	92
OBR. 10.5: SEKVENCE PŘEPÍNÁNÍ	93
OBR. 10.6: ADAPTIVNÍ ŘÍZENÍ: JEDNODUCHÝ SAMOČINNĚ SE NASTAVUJÍCÍ REGULÁTOR	94
OBR. A.1: CELKOVÉ ZAPOJENÍ ME SCHÉMATU.....	108
OBR. A.2: OBRÁZKY JEDNOTLIVÝCH SUBSYSTÉMŮ	109
OBR. A.3: VNITŘNÍ STRUKTURA BLOKU REGULÁTORŮ	111
OBR. A.4: DIALOG PRO ZADÁVÁNÍ PARAMETRŮ BLOKU REGULATOR.....	111
OBR. A.5: VNITŘNÍ STRUKTURA BLOKU REGULATOR.....	112
OBR. A.6: VNITŘNÍ STRUKTURA BLOKU IDENTIFIKACE	113
OBR. A.7: DIALOG PRO ZADÁVÁNÍ PARAMETRŮ BLOKU ESTIMATORY	113
OBR. A.8: VNITŘNÍ STRUKTURA BLOKU ESTIMATORY.....	114
OBR. A.9: DIALOG PRO ZADÁVÁNÍ PARAMETRŮ BLOKU NADRAZENY CLEN	115
OBR. A.10: VNITŘNÍ STRUKTURA BLOKU NADRAZENY CLEN	117
OBR. A.11: KNIHOVNA REKURZIVNÍCH IDENTIFIKAČNÍCH ALGORITMŮ.....	118

SEZNAM TABULEK

TABULKA 1 – PRŮBĚH ZMĚNY PARAMETRŮ MODELU ŘÍZENÉHO SYSTÉMU.....	78
TABULKA 2 – SEZNAM JEDNOTLIVÝCH DVOJIC ESTIMÁTOR-ADAPTIVNÍ REGULÁTOR V NAVRŽENÉM MULTIESTIMAČNÍM SCHÉMATU.....	79
TABULKA 3 – KRITERIA KVALITY REGULACE PRO SIMULAČNÍ OVĚŘOVÁNÍ	86
TABULKA 4 – KRITERIA KVALITY REGULACE PRO SIMULAČNÍ OVĚŘOVÁNÍ	95
TABULKA 5 – POPIS VSTUPŮ A VÝSTUPŮ BLOKU REGULÁTORŮ	109
TABULKA 6 – POPIS VSTUPŮ A VÝSTUPŮ BLOKU NADRAZENÝ ČLEN	109
TABULKA 7 – POPIS VSTUPŮ A VÝSTUPŮ BLOKU IDENTIFIKACE	110
TABULKA 8 – PARAMETRY ZADÁVANÉ V DIALOGU BLOKU REGULÁTORŮ	111
TABULKA 9 – PARAMETRY ZADÁVANÉ V DIALOGU BLOKU ESTIMÁTORŮ	113
TABULKA 10 – PARAMETRY ZADÁVANÉ V DIALOGU BLOKU NADRAZENÝ ČLEN	116
TABULKA 11 – POPIS VSTUPŮ A VÝSTUPŮ BLOKU KNIHOVNY.....	119

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

Symbols

$A()$	Polynom jmenovatele deterministické části přenosu modelu procesu
$B()$	Polynom čitatele deterministické části přenosu modelu procesu
$C()$	Polynom čitatele stochastické části přenosu modelu procesu
$D()$	Polynom jmenovatele stochastické části přenosu modelu procesu; polynom pravé části diofantické rovnice
$F()$	Polynom jmenovatele deterministické části přenosu modelu procesu
$y(k)$	Regulovaná veličina
$u(k)$	Akční veličina (výstup regulátoru)
$w(k)$	Žádaná hodnota; pomocná proměnná
$e(k)$	Regulační odchylka; náhodný šum
$n(k)$	Bílý šum; neměřitelná porucha
$\phi(k-1)$	Vektor dat (regresní vektor)
θ	Vektor parametrů
$\hat{\theta}$	Vektor odhadu parametrů
$\hat{\theta}_f$	Filtrovaná hodnota vektoru odhadu parametrů
\hat{e}	Chybový vektor
$C(k)$	Čtvercová kovarianční matice
$\hat{e}(k)$	Chyba predikce (a priori)
$\hat{y}(k k-1)$	Predikce výstupu modelu na základě k-1 pozorování
q	Operátor posunu (tj. $q^{-1}x(k) = x(k-1)$,)
d	Počet kroků dopravního zpoždění
T_0	Perioda vzorkování

\mathbf{F}	Matice dat
F	Operátor objektu
F_M	Operátor modelu
y_M	Výstup modelu
u_M	Vstup modelu
E	Operátor střední hodnoty
$v(k)$	Měřitelná porucha
n_a	Počet koeficientů polynomu $A(\)$
n_b	Počet koeficientů polynomu $B(\)$
n_c	Počet koeficientů polynomu $C(\)$
n_d	Počet koeficientů polynomu $D(\)$
n_f	Počet koeficientů polynomu $F(\)$
N_e	Počet dvojic estimátor-adaptivní regulátor
c_k	Index aktivní dvojice estimátor-adaptivní regulátor v kroku k
$K(\)$	Polynom jmenovatele přenosu regulátoru (integrátor)
$P(\)$	Polynom jmenovatele přenosu regulátoru
$Q(\)$	Polynom čitatele zpětnovazební části přenosu regulátoru
$R(\)$	Polynom čitatele přímovazební části přenosu regulátoru
\mathbf{I}	Jednotková matice
$L(k)$	Zesílení algoritmu
λ	Faktor zapomínání (exponenciálního)

λ_0	Počáteční hodnota faktoru zapomínání (exponenciálního)
$\varepsilon(k)$	Faktor směrového zapomínání
$\varphi(k)$	Hodnota adaptivního směrového zapomínání
$\eta(k)$	Skutečná chyba modelování - residuum (a posteriori); pomocný skalár
$\nu(k)$	Pomocný skalár
$\lambda(k)$	Pomocný skalár
ρ	Pomocný skalár
$\xi(k-1)$	Pomocný skalár
α	Konstanta
β	Konstanta
γ	Konstanta
δ	Konstanta
tr	Stopa matice
Cov	Kovarianční matice
\max	Maximum
\min	Minimum
\dim	Rozměr vektoru/matice
$z(k)$	Instrumentální proměnná (instrument)
$y_u(k)$	Filtrovaná hodnota výstupu modelu
$\hat{a}_i(k)$	Odhad i-tého parametru polynomu $A(\)$
$\hat{b}_i(k)$	Odhad i-tého parametru polynomu $B(\)$

$\hat{c}_i(k)$	Odhad i-tého parametru polynomu $C(\)$
$\psi(k)$	Vektor gradientů
$y^F(k)$	Filtrovaná hodnota regulované veličiny
$u^F(k)$	Filtrovaná hodnota akční veličiny (výstupu regulátoru)
$\hat{e}^F(k)$	Filtrovaná hodnota chyby predikce
$\eta^F(k)$	Filtrovaná hodnota skutečné chyby modelování
$w^F(k)$	Filtrovaná hodnota pomocné proměnné
κ_1	Konstanta (práh)
κ_2	Konstanta (práh)
eps	Práh rozhodování
q_u	Penalizační konstanta
$M(\)$	Pomocný polynom
M	Hloubka paměti
$J_i(k)$	Kriterium (ukazatel jakosti)
α_k, β_k	Váhy
t_k	Okamžik vzorkování
π	Počet přepnutí
τ_D	Prodleva mezi časy přepnutí
$G_d(s)$	Přenosová funkce deterministické části modelu řízeného procesu
$G_s(s)$	Přenosová funkce stochastické části modelu řízeného procesu

$G(s)$	Celkový přenos řízeného systému
T_i	Časová konstanta
N_D	Prodleva mezi jednotlivými přepnutími
S_u	Sumace kvadrátů přírůstků akční veličiny
S_y	Sumace kvadrátů regulační odchylky

Zkratky

ARX	AutoRegressive with eXogenous input
ARMAX	AutoRegressive Moving Average with eXogenous input
ARARX	AutoRegressive AutoRegressive with eXogenous input
OE	Output Error Model
BJ	Box-Jenkins Model
FIR	Finite Impulse Response
RLS	Rekurzivní metoda nejmenších čtverců
RELS	Rekurzivní rozšířená metoda nejmenších čtverců
RIV	Rekurzivní metoda instrumentální proměnné
ERIV	Rozšířená rekurzivní metoda instrumentální proměnné
RPEM	Rekurzivní metoda predikčních chyb

1 ÚVOD

Efektivní řízení dynamických systémů je ve středu zájmu teoretického zkoumání i praktických aplikací již delší dobu. Předpokladem efektivního řízení daného objektu je znalost jeho vlastností. Je zřejmé, že čím více má být řízení efektivnější, tím dokonaleji a přesněji musíme znát vlastnosti řízeného objektu, vytváříme tzv. model objektu. Ztotožnění modelu s vyšetřovaným objektem je cílem identifikace systémů.

Jednou z oblastí identifikace systémů je získávání parametrů modelu procesu z experimentálně naměřených dat (experimentální identifikace). Úkolem experimentální identifikace je tedy vytvoření modelu a to na základě pozorování vstupů a výstupů tak, aby statické i dynamické chování vytvořeného modelu bylo blízké chování systému reálného. Identifikace systémů nalézá široké uplatnění v mnoha oblastech. V oblasti řízení jsou metody identifikace použity pro získání vhodných modelů pro syntézu regulátoru, návrh prediktivního řízení nebo simulace. V aplikacích zabývajících se zpracováním signálu jsou modely získané pomocí identifikace systémů použity pro spektrální analýzu, odhalení poruch, rozpoznávání obrazců, adaptivní filtraci. Metody identifikace systémů jsou též úspěšně využívány i v netechnických oborech jako jsou biologie, ekologie a ekonomika.

Pro určení parametrů těchto modelů lze použít jednorázové nebo průběžné metody identifikace. *Jednorázová identifikace* je taková, kdy k určení parametrů využíváme množinu bodů vstupních a výstupních signálů odpovídající určitému časovému úseku a jednorázově provedeme odhad parametrů. Tato metoda je vhodná pro jednoduché systémy s neměnnými dynamickými vlastnostmi. *Průběžná identifikace* je taková, kdy parametry matematického modelu vyhodnocujeme průběžně v reálném čase.

S rozvojem výpočetní techniky se stále více dostávají do popředí adaptivní řídicí systémy, které jsou schopny reagovat na změny parametrů procesu, způsobené změnami v provozních režimech, změnami vlastností surovin, paliva, zařízení apod., se kterými se pevně seřízené regulátory nemohou vyrovnat. V adaptivním řízení je úloha identifikace stejně důležitá jako role syntézy regulátoru.

Součástí skupiny adaptivní regulátorů jsou i samočinně se nastavující regulátory, které jsou založeny na průběžné identifikaci odhadů proměnlivých parametrů modelu

procesu a následné syntéze regulátoru. Je proto třeba použít dostatečně přesné a spolehlivé rekurzivní identifikační metody, které jsou schopny tyto parametry identifikovat v poměrně krátkém čase.

Identifikace pro adaptivní řízení má ovšem svá specifika, která vedou k tomu, že se v převážné míře odhadují parametry regresního modelu (ARX – *AutoRegressive with eXogenous input*) a používá se metoda nejmenších čtverců. V určitých situacích, kdy je měřená veličina výrazně zatížena šumem, jehož vlastnosti nelze charakterizovat parametry odhadovaného modelu (případ je častější za situace, kdy se pracuje s omezenou strukturou identifikovaného modelu), vede MNC k odhadům vychýlených a nekonzistentních parametrů a následně k návrhu regulátoru, který nemusí spolehlivě pracovat.

Problémy lze odstranit použitím jiných složitějších typů modelů, např. použitím modelu ARMAX (*AutoRegressive Moving Average with eXogenous input*), modelu OE, který minimalizuje chybu výstupu (*Output Error Model*) aj. Případně je potřeba použít pro odhad parametrů modelů jiných identifikačních procedur. Jedná se zejména o metodu instrumentální proměnné (*Instrumental Variable Method*) a rozšířenou metodu instrumentální proměnné (*Extended Instrumental Variable Method*), které se používají pro odhad parametrů modelu ARX. Pro odhad parametrů modelu ARMAX se používá rozšířená metoda nejmenších čtverců (*Extended Least Squares Method*), popř. je možno použít metodu predikčních chyb (*Prediction Error Method*).

Cílem disertační práce je tedy zhodnotit jiné metody pro průběžný odhad parametrů modelu procesu pro návrh adaptivního řízení a porovnat je s běžně používanou metodou nejmenších čtverců, zajištění paralelního běhu těchto jednotlivých vybraných algoritmů a návrh nadřazeného členu, který bude na základě vhodně zvoleného kritéria (kritérií) řídit výběr vhodné metody pro odhad parametrů. Vybraná metoda bude následně použita pro syntézu regulátoru za účelem zlepšení spolehlivosti adaptivních řídicích systémů.

2 LITERÁRNÍ REŠERŠE

Identifikace systémů je předmětem aktivního vědeckého zájmu v oblastech jako je řízení, zpracování signálu a komunikace. Odhad parametrů pomocí metody nejmenších čtverců se stal snad nejvíce studovaným a realizovaným způsobem identifikace stochastických systémů.

Také při identifikaci pro adaptivní řízení se v převážné míře používá metoda nejmenších čtverců pro odhad parametrů regresního modelu (ARX) a předpokládá se, že na měřenou veličinu působí pouze bílý šum [4], [7].

V případě, že měřená veličina je výrazně zatížena šumem a vlastnosti tohoto šumu nelze charakterizovat parametry odhadovaného modelu (případ je častější za situace, kdy se pracuje s omezenou strukturou identifikovaného modelu), vede metoda nejmenších čtverců k odhadům parametrů, které jsou vychýlené a nekonzistentní [31], [38], [45], [47]. Tento problém může také nastat v případě, že je identifikace prováděna z dat získaných z uzavřeného regulačního obvodu, kde nejsou splněny podmínky kladené na tuto metodu.

Tyto problémy lze odstranit použitím jiných složitějších typů modelů, které ve svém popisu obsahují i část umožňující popsat chování působícího neměřitelného šumu. Případně je potřeba použít pro odhad parametrů modelů jiných identifikačních procedur, které jsou schopny poskytnout nevychýlený a konzistentní odhad za méně omezujících podmínek než metoda nejmenších čtverců.

Základní pojmy z oblasti identifikace systémů, podrobný popis rekurzivních i nerekurzivních identifikačních metod a jejich vlastností lze nalézt např. v [45]. Úvodní kapitoly jsou věnovány analýze vstupních signálů a jejich vhodnosti pro identifikační experiment, lineární regresi a klasifikaci nejpoužívanějších lineárních dynamických modelů. Samostatné kapitoly jsou věnovány popisu a analýze vlastností metody predikčních chyb (PEM) a metody instrumentální proměnné (IV). Autoři také uvádí základní, rozšířenou a optimální verzi metody instrumentální proměnné, včetně volby tzv. instrumentu. Další část knihy je věnována popisu rekurzivních verzí algoritmů uvedených v předchozích kapitolách. Pro model ARX jsou to rekurzivní metoda nejmenších čtverců (RLS) a rekurzivní metoda instrumentální proměnné (RIV) včetně návrhu faktoru

zapomínání (exponenciální zapomínání) pro identifikaci časově proměnných parametrů a dále je uveden algoritmus rekurzivní rozšířené metody instrumentální proměnné (ERIV). Pro modely složitějších struktur je zde uvedena rekurzivní verze metody predikčních chyb (RPEM) a její zjednodušená varianta rozšířená metoda nejmenších čtverců (RELS, RPLR). V závěru knihy se autoři zabývají identifikací systémů v uzavřeném regulačním obvodu, určování struktury modelu a jeho ověřování a dále praktickým aspektům souvisejícím s podmínkami identifikačního experimentu, určování struktury modelu, volbou identifikační metody, robustností odhadu parametrů, ověřování modelu a programovým vybavením.

Rekurzivním odhadem parametrů, který je nezbytný pro aplikaci samočinně se nastavujících regulátorů, se zabývá i [47]. Autoři uvádí několik základních metod pro odhad parametrů modelu ARX (rekurzivní metoda nejmenších čtverců) a ARMAX (rozšířená metoda nejmenších čtverců, zjednodušená varianta metody predikčních chyb – rekurzivní metoda maximální věrohodnosti), dále je diskutován vliv počátečních podmínek pro start rekurzivních identifikačních algoritmů a konvergenční vlastnosti těchto rekurzivních algoritmů. Další části jsou věnovány samočinně se nastavujícím regulátorům, především metodám syntézy.

Rozšířenou metodou instrumentální proměnné se zabývá i [18]. Zde lze nalézt podrobnější popis této metody a také příklady aplikací.

Metoda nejmenších čtverců patří mezi nejčastěji používané algoritmy identifikace v adaptivním řízení [4], [7]. V případě, že se jedná o systém s proměnnými parametry (což je v praxi splněno téměř vždy), klasický rekurzivní algoritmus nejmenších čtverců se není schopen adaptovat na změny těchto parametrů, a je proto nutné použít některou z modifikací tohoto algoritmu, které umožňují zajistit sledování časově proměnných parametrů. Převážná většina modifikací spočívá v zavedení faktoru zapomínání. Zavedení faktoru exponenciálního zapomínání a také využití Kalmanova filtru pro odhad parametrů je ukázáno např. v [18], [38], [45], [47]. Lepších výsledků je možno dosáhnout s použitím faktoru tzv. směrového zapomínání ([27], [28], [29], [47]). Většina faktorů zapomínání uvažuje stejnou rychlost změny parametrů (nastavuje stejnou váhu všem odhadovaným parametrům), pokud je rychlost změny jednotlivých parametrů rozdílná, je vhodnější

použít např. maticové exponenciální zapomínání [31], [11]. Podobný přístup nabízí i tzv. *multiple forgetting method* [46], která je podobná maticovému zapomínání, ale umožňuje zajištění sledování měnících se parametrů i v případě, že faktory zapomínání příslušné jednotlivým parametrům nepostihují dostatečně rychlost jejich změny. Přehled nejpoužívanějších faktorů zapomínání lze nalézt např. v [15], [30], [10]. Další modifikaci rekurzivní metody nejmenších čtverců, vhodnou pro adaptivní řízení, lze nalézt v [40]. Úprava spočívá v tom, že základní kritérium je rozšířeno o vážený přírůstek odhadů parametrů, což poskytuje možnost lépe řídit rychlost adaptace. Další přístup ke zlepšení chování algoritmu rekurzivní metody nejmenších čtverců, který spočívá v přímé modifikaci kovarianční matice, je uveden v [4].

Nový přístup pro zajištění sledování časově proměnných parametrů navrhuje [49]. Základní myšlenka tohoto přístupu spočívá v tom, že na rozdíl od klasického přístupu, kde se předpokládá, že systém je lokálně konstantní a kde rychlé změny v parametrech systému mohou způsobit numerickou nestabilitu algoritmu, je u tohoto přístupu implicitně předpokládán proměnný model systému a na tomto základě je pak odvozen výsledný rekurzivní algoritmus pro odhad parametrů.

Při adaptivním řízení mohou neměřitelné poruchy a použitý jednoduchý model, který dostatečně nevystihuje dynamiku řízeného procesu a mechanismus působící poruchy způsobit, že může docházet k nekonečnému trvalému nárůstu (tzv. nekonečnému driftu) hodnot odhadovaných parametrů. V určitých případech může tento nekonečný drift vést k destabilizování uzavřeného obvodu, což může být chápáno jako vybuzení, které vede k získání nových hodnot parametrů a následně ke stabilizování uzavřeného obvodu. Nicméně, jakmile je obvod opět stabilizován, drift v parametrech způsobí jeho opětovné destabilizování a cyklus se opakuje. Tento jev je znám pod názvem *bursting*. Nekonečný drift parametrů a *bursting* mohou mít za následek, že regulátor nebude spolehlivě pracovat. Existuje několik metod, které umožňují zmírnit tyto problémy. Krátký přehled jednotlivých metod, jejich výhod a omezení, je uveden v článku [21]. Autoři také uvádí vlastní metodu tzv. selektivní paměti, která je snadno implementovatelná a zaručuje stabilitu nezávisle na vlastnostech působícího šumu a stavitelných parametrech a je založena na myšlence výběru pouze těch dat, které mají vysoký informační obsah.

Uvedená metoda vychází z metody *deathzone* [47], vyžaduje však méně apriorních informací. Informační obsah dat je posuzován pomocí Fisherovy informační matice a vyhodnocování rozptylu estimátoru. Odhad parametrů je pak aktualizován pouze v případě, že informační matice nebo rozptyl estimátoru roste.

Srovnáním některých identifikačních metod se zabývalo nezávisle na sobě několik autorů např. [9], [24], [44], [11]. Srovnání šesti rekurzivních identifikačních algoritmů je uvedeno v [44]. Je provedeno srovnání výpočetní náročnosti a otestována jejich konvergence na dvou diskretních systémech čtvrtého řádu.

Porovnání a vyhodnocení šesti identifikačních algoritmů pro odhad parametrů tří lineárních diskretních systémů (systém druhého řádu kmitavý, systém druhého řádu s neminimální fází a systém třetího řádu s dopravním zpožděním) je provedeno v [24]. Identifikace je prováděna pomocí vybraných rekurzivních metod (metoda nejmenších čtverců, zevšeobecněná metoda nejmenších čtverců, metoda instrumentální proměnné, stochastická aproximace, korelační analýza s odhadem parametrů pomocí nejmenších čtverců a Fourierova analýza s použitím modelu se třemi neznámými parametry).

Srovnání vlastností tří nejběžnějších faktorů zapomínání pro zajištění sledování časově proměnlivých parametrů lze nalézt v [11]. Vhodnost použití jednotlivých faktorů zapomínání a jejich výhody a nevýhody jsou uvedeny při identifikaci proměnlivých parametrů modelu na základě vyhodnocování vstupně-výstupních dat získaných z uzavřeného regulačního obvodu. V závěru článku jsou také uvedeny dvě možnosti odstranění problému velkého nárůstu kovarianční matice, který vzniká v důsledku nedostatečné excitace ve vstupních datech (především při použití exponenciálního zapomínání). Tento nárůst může vést ke zhroucení identifikačního algoritmu. Jednou z uvedených možností zabránění vzniku tohoto problému, je použití algoritmu, který zajišťuje udržování stopy kovariační matice na konstantní hodnotě – algoritmus konstantní stopy. Druhý uvedený způsob spočívá v detekci dostatečného vybuzení a následné aktualizaci odhadu parametrů a kovarianční matice. Detekce dostatečného vybuzení je provedena na základě testu, který je založený na sledování velikosti rozptylů ve vstupně-výstupních datech.

Kromě již uvedených rekurzivních metod identifikace může být pro odhad parametrů v reálném čase použita také nerekurzivní (jednorázová) metoda nejmenších čtverců [26]. Jednorázová metoda nejmenších čtverců poskytuje přesnější odhady parametrů než její rekurzivní varianta. Výpočet odhadů parametrů není prováděn ze všech získaných dat až do aktuálního kroku, ale pouze z vybrané části, která je specifikována tzv. oknem. Šířka tohoto výběru může být volena jako konstantní, což má ale za následek zhoršení odhadů parametrů v případě, že se parametry systému mění. Proto autoři navrhli algoritmus, který umožňuje změnu šířky okna v závislosti na detekci rychlosti změny parametrů a tak je umožněno sledování pozvolných i náhlých změn a výsledný algoritmus poskytuje lepší výsledky než algoritmus s pevnou šířkou okna.

Využitím teoretických poznatků na poli rekurzivní identifikace pro možné praktické využití rekurzivních identifikačních metod v aplikacích v průmyslu se zabývá [9]. Autoři srovnávají rekurzivní metodu nejmenších čtverců, rekurzivní rozšířenou metodu nejmenších čtverců, rekurzivní metodu instrumentální proměnné a její variantu, rozšířenou rekurzivní metodu instrumentální proměnné. Dále se zabývají možnou eliminací trvalých odchylek v naměřených datech. Uvedené metody byly pak otestovány na dvou laboratorních modelech.

Možnost zlepšení kvality regulačního pochodu nabízí tzv. multimodelový přístup (např. [36], [37]), který je založen na vytvoření (popř. průběžném vytváření) lokálních lineárních modelů pro různé provozní stavy, kde každému z těchto modelů je přiřazen odpovídající regulátor. Regulační obvod pak obsahuje tzv. supervizor, který z procesních dat na základě zvoleného kritéria určuje, který model lépe reprezentuje proces v příslušném čase a následně dochází k přepnutí na jeho odpovídající regulátor.

Další možnost zlepšení kvality regulačního pochodu v decentralizovaném řízení pomocí tzv. logického supervizoru uvádí [22]. V tomto případě logický supervizor řeší možnost zapínání a vypínání průběžné identifikace a také volbu a přepínání regulátorů mezi režimem s pevně nastavenými parametry získanými z posledních platných hodnot parametrů a adaptivním režimem v jednotlivých smyčkách na základě vyhodnocování zvoleného kritéria.

Určité míry zlepšení spolehlivosti adaptivních řídicích systémů je také možné dosáhnout pomocí tzv. vícenásobného odhadu [23], [12]. Princip je podobný multimodelovému přístupu, ale v tomto případě jsou parametry procesu průběžně odhadovány na základě paralelního běhu několika zvolených rekurzivních identifikačních metod stejného typu. Takto získané odhady parametrů jsou použity pro syntézu jednotlivých regulátorů. Nadřazený člen tzv. supervizor, pak na základě zvoleného kritéria rozhoduje, který z regulátorů bude použit pro vygenerování akčního zásahu. Kromě toho, nadřazený člen zajišťuje také restart jednotlivých rekurzivních metod identifikace, pokud jsou získané odhady nevyhovující.

V případě, že lineární model neposkytuje uspokojivé výsledky, je jedno z možných vysvětlení, že proces vykazuje významně nelineární chování. V takovém případě je vhodné zvolit pro řízený proces popis pomocí modelů nelineárních, které ale musí být dostatečně flexibilní, jinak mohou poskytovat horší výsledky než modely lineární. Možnostmi identifikace lineárních i nelineárních systémů se zabývá [38]. První část je věnována lineární, lokální nelineární a globální nelineární optimalizaci, včetně možnosti použití moderního přístupu k optimalizaci pomocí neuronové sítě, genetických a fuzzy algoritmů. Různými typy statických lineárních a nelineárních modelů se zabývá část druhá. V této části jsou diskutovány lineární, polynomiální a tzv. *look-up table* modely a dále modely fuzzy a neuro-fuzzy. Část třetí se zabývá dynamickými lineárními a nelineárními modely, jejich použitím a možnosti jejich identifikace. Lineární modely jsou zastoupeny modely ARX, ARMAX, ARARX, OE, BJ. Pro identifikaci modelů ARX a ARMAX jsou uvedeny rekurzivní verze algoritmů pro identifikaci jejich parametrů. Nelineární modely jsou zastoupeny polynomiálními modely (*Kolmogorov-Gabor Polynomial Models* – NARX, NARMAX, NOE, *Volterra-Series Models*, NDE, *Hammerstein Models*, *Wiener Models*), dynamickými fuzzy modely a dynamickými lokálně lineárními Neuro-Fuzzy modely. Poslední část je věnována aplikacím těchto moderních způsobů identifikace nelineárních systémů.

3 CÍLE DISERTAČNÍ PRÁCE

V rámci mé doktorské disertační práce se zaměřuji na možnost zlepšení spolehlivosti a výkonu samočinně se nastavujících regulátorů.

Cíle doktorské disertační práce lze shrnout do následujících bodů:

1. Simulační a reálné ověření vybraných rekurzivních identifikačních algoritmů pro odhad parametrů modelů ARX, ARMAX, OE v uzavřeném regulačním obvodu pro vybraný typ adaptivního číslicového regulátoru.
2. Na základě výsledků, získaných ze simulačního a reálného ověření provést volbu vhodných rekurzivních metod identifikace pro odhad parametrů modelu procesu v uzavřeném regulačním obvodu pro účely návrhu adaptivního regulátoru pro adaptivní řízení.
3. Zajištění paralelního běhu jednotlivých vybraných dvojic identifikačních algoritmů-adaptivních regulátorů – paralelní multiestimační schéma.
4. Návrh nadřazeného členu pro paralelní multiestimační schéma pro přepínání jednotlivých zvolených dvojic identifikačních algoritmů-adaptivních regulátorů za účelem zlepšení průběhu přechodového děje během regulačního pochodu.

Úkoly nadřazeného členu:

- volba vhodné dvojice estimátor-adaptivní regulátor,
 - kontrola jednotlivých metod identifikace,
 - kontrola návrhu adaptivního regulátoru.
5. Simulační a reálné ověření takto navržené složitější struktury (paralelního multiestimačního schématu) a její srovnání s jednoduchou strukturou samočinně se nastavujícího regulátoru.

4 TYPY MODELŮ

Jedním ze základních kroků při identifikaci se rozumí výběr vhodného typu modelu. Struktura modelu by měla co nejlépe vystihovat vlastnosti reálného systému a také účel pro který je model určen.

Identifikovaná soustava může být deterministická nebo stochastická. U deterministické soustavy je možno ze znalosti vstupního signálu a okamžitého stavu soustavy přesně určit velikost výstupního signálu v následujícím časovém okamžiku, kdežto u stochastické soustavy jen s určitou pravděpodobností. Rušivé vlivy, které mají za následek stochastické chování soustavy, vznikají jednak uvnitř soustavy a jednak chybami měření veličin. Teoreticky vzato, každý deterministický signál při realizaci a měření přibírá rušivou složku a záleží jen na poměru této složky k užitečnému signálu, zda jej nazveme deterministický nebo stochastický. Z tohoto důvodu se v této části zaměříme jen na popis základních typů diskrétních lineárních modelů stochastických soustav využívaných při identifikaci s tím, že deterministický model je jen zvláštním případem stochastického modelu.

Obecný lineární model:

$$y(k) = \frac{B(q^{-1})}{A(q^{-1})F(q^{-1})}u(k) + \frac{C(q^{-1})}{A(q^{-1})D(q^{-1})}n(k) \quad (4.1)$$

Z obecného lineárního modelu lze jeho zjednodušováním odvodit níže uvedené typy lineárních modelů (kde q značí operátor posunu, tj. platí $q^{-1}x(k) = x(k-1)$, $u(k)$ je vstup do modelu, $y(k)$ značí výstup modelu a $n(k)$ je bílý šum).

a) model ARX - ($C = D = F = 1$)

$$y(k) = \frac{B(q^{-1})}{A(q^{-1})}u(k) + \frac{1}{A(q^{-1})}n(k) \quad (4.2)$$

b) model ARMAX - ($D = F = 1$)

$$y(k) = \frac{B(q^{-1})}{A(q^{-1})}u(k) + \frac{C(q^{-1})}{A(q^{-1})}n(k) \quad (4.3)$$

c) model OE (*Output error model*) - ($A = C = D = 1$)

$$y(k) = \frac{B(q^{-1})}{F(q^{-1})}u(k) + n(k) \quad (4.4)$$

d) model BJ (*Box-Jenkins model*) - ($A = 1$)

$$y(k) = \frac{B(q^{-1})}{F(q^{-1})}u(k) + \frac{C(q^{-1})}{D(q^{-1})}n(k) \quad (4.5)$$

e) model ARARX ($C = F = 1$)

$$y(k) = \frac{B(q^{-1})}{A(q^{-1})}u(k) + \frac{1}{A(q^{-1})D(q^{-1})}n(k) \quad (4.6)$$

f) model ARARMAX ($F = 1$)


$$y(k) = \frac{B(q^{-1})}{A(q^{-1})}u(k) + \frac{C(q^{-1})}{A(q^{-1})D(q^{-1})}n(k) \quad (4.7)$$

g) model FIR ($A = F = C = D = 1$)


$$y(k) = B(q^{-1})u(k) + n(k) \quad (4.8)$$

Jednotlivé polynomy mají následující tvar


$$\begin{aligned} A(q^{-1}) &= 1 + a_1q^{-1} + \dots + a_{n_a}q^{-n_a} \\ B(q^{-1}) &= b_1q^{-1} + b_2q^{-2} + \dots + b_{n_b}q^{-n_b} \\ C(q^{-1}) &= 1 + c_1q^{-1} + \dots + c_{n_c}q^{-n_c} \\ D(q^{-1}) &= 1 + d_1q^{-1} + \dots + d_{n_d}q^{-n_d} \\ F(q^{-1}) &= 1 + f_1q^{-1} + \dots + f_{n_f}q^{-n_f} \end{aligned} \quad (4.9)$$




ARX




OE




ARMAX




BJ



ARARX



FIR



Obr. 4.1: Přehled běžných lineárních dynamických modelů

Deterministická a stochastická část modelu mohou obecně obsahovat společně nebo různé póly, to je důvodem pro zavedení všech výše uvedených variant modelů (viz. Obr. 4.1), které tedy umožňují různými způsoby popsat stochastickou část modelu (tj. část, která charakterizuje působící šum) a tak poskytnout jistou variabilitu v popisu působícího šumu.

Přehled nejvýznamnějších lineárních vstupně/výstupních modelů je uveden na předchozím obrázku (viz. Obr. 4.1). Všechny modely na levé straně obrázku (ARX, ARMAX, ARARX) náleží do třídy modelů *chyby rovnice*. Jejich charakteristikou je, že filtr $1/A(q)$ je společný jak pro deterministickou část modelu procesu tak i pro stochastickou část modelu popisující šum. U těchto modelů se tedy předpokládá, že šum přímo neovlivňuje výstup modelu $y(k)$, ale místo toho vstupuje do modelu před filtrem $1/A(q)$. Modely uvedené na pravé straně obrázku (OE, BJ, FIR) (viz. Obr. 4.1) náleží do třídy modelů s *chybou na výstupu*. Modely této třídy jsou charakterizovány tím, že stochastická část modelu popisující šum je nezávislá na deterministické části modelu procesu, předpokládá se tedy, že šum ovlivňuje výstup procesu přímo.

Poznámka:

Z důvodu zjednodušení se předpokládá, že procesy a modely nemají dopravní zpoždění. Nicméně, dopravní zpoždění dT_0 může být jednoduše zavedeno nahrazením vstupu $u(k)$ vstupem zpožděným o d kroků $u(k-d)$. Dále se předpokládá, že procesy a modely nemají přímou vazbu ze vstupu na výstup tzn., že vstup $u(k)$ neovlivňuje bezprostředně výstup $y(k)$. Takže, výrazy jako $b_0u(k)$ se v diferenčních rovnicích nevyskytují. Tento předpoklad je splněn pro téměř každý reálný proces.

5 KVALITA IDENTIFIKACE


Při známé struktuře modelu, shodu modelu (operátoru modelu) s operátorem objektu charakterizujeme účelovou funkcí $J[s(F, F_M)]$, kde s je tzv. ztrátová funkce, F a F_M operátor objektu, resp. modelu. Podle účelové funkce je možné porovnávat různé struktury modelu. Výběr účelové funkce výrazně ovlivňuje algoritmus řešení úlohy identifikace.

V prvním kroku pro kvantitativní ohodnocení stupně blízkosti operátorů volíme vhodnou ztrátovou funkci $s(F, F_M)$. Blížkost operátorů se posuzuje na základě odchylek odpovídajících signálů nebo parametrů operátorů modelu a objektu. Protože přímo pozorovatelné jsou především signály, rozeznáváme v zásadě tři způsoby formování odchylky mezi modelem a objektem.

1) Chyba výstupu

Vytváříme odchylku mezi výstupy paralelně zapojeného objektu a modelu.

Metody identifikace pracující s chybou výstupu jsou nejpřesnější, protože porovnávají přímo reakci (odezvu) modelu a objektu.




Obr. 5.1: Chyba výstupu

Ze schématu lze odvodit následující rovnici:

$$e = y - y_M = y - F_M(u) \quad (5.1)$$

2) Chyba vstupu

Vytváříme odchylku na straně vstupních signálů modelu a objektu v sériovém zapojení.




Obr. 5.2: Chyba vstupu

Ze schématu lze odvodit následující rovnici:

$$e = u - u_M = u - F_M^{-1}(y) \quad (5.2)$$

kde u_M je vstup modelu, generující výstup y . Samozřejmě, F_M^{-1} je inverzní operátor a tedy F_M musí být invertovatelný.

3) Chyba rovnice



Obr. 5.3: Chyba rovnice

Ze schématu lze odvodit následující rovnici:

$$e = F_{M_2}^{-1}(y) - F_{M_1}(u) \quad (5.3)$$

kde F_{M_2} představuje invertovatelnou část modelu a celý model je dán jako $F_M = F_{M_1}F_{M_2}$.
Chyba je přímo generovaná ze vstupně-výstupního popisu jako nesoulad mezi levou a pravou stranou rovnice.

6 STOCHASTICKÉ METODY IDENTIFIKACE

V praxi vždy na zkoumaný systém působí poruchy a ani vstupy do něj nejsou zcela deterministické. Z tohoto důvodu je nutné věnovat pozornost metodám, které berou tyto rušivé signály a chyby měření do úvahy.

Velmi vhodnými stochastickými metodami identifikace jsou tzv. regresní metody, které se snaží minimalizovat účinky šumu a jsou založeny na metodě nejmenších čtverců.

6.1 Regresní metody

Regresní analýza je vhodná pro vyšetřování nejen statických, ale i dynamických systémů. Prudký rozvoj výpočetní techniky způsobil i rozvoj a zdokonalování regresních metod.

6.1.1 Požadavky na odhad parametrů

Když $\hat{\theta}$ je odhadnutý vektor parametrů θ , potom

nevychýlenost (nestrannost) odhadu znamená, že když $\hat{\theta}(k)$ je odhad vytvořený na základě k měření, potom pro každé k musí platit

$$E\{\hat{\theta}(k)\} = \theta, \text{ kde } E \text{ značí operátor střední hodnoty}$$

konzistence znamená, že pro libovolný vektor konstant $\varepsilon > 0$ platí

$$\lim_{k \rightarrow \infty} P[\theta - \varepsilon < \hat{\theta}(k) < \theta + \varepsilon] = 1, \text{ kde } P \text{ značí pravděpodobnost}$$

navíc platí, že odhad je konzistentní v středně kvadratickém smyslu, když splňuje podmínku

$$\lim_{k \rightarrow \infty} \text{Cov}(\hat{\theta}(k)) = 0, \text{ kde } \text{Cov} \text{ značí kovarianční matici}$$


vydatnost (efektivnost), tj., když mezi odhadem $\hat{\theta}$ a každým jiným odhadem $\bar{\theta}$ platí

$$\text{Cov}(\bar{\theta}) - \text{Cov}(\hat{\theta}) \geq 0$$

V případě skaláru je minimální ten odhad, který má minimální rozptyl. Při nulovém rozptylu přechází pravděpodobnost v jistotu.

6.1.2 Identifikace dynamických systémů pomocí metody nejmenších čtverců

Uvažujme diskrétní systém uvedený na Obr. 6.1 se vstupním signálem $u(k)$ a s výstupem $y(k)$. Na systém působí měřitelné $v(k)$ a neměřitelné $n(k)$ poruchy.



Obr. 6.1: Blokové schéma diskrétního systému

Model tohoto systému může být zapsán v následující formě

$$A(q^{-1})y(k) = B(q^{-1})u(k) + D(q^{-1})v(k) + C(q^{-1})n(k) \quad (6.1)$$

kde

$$\begin{aligned} A(q^{-1}) &= 1 + a_1q^{-1} + \dots + a_{n_a}q^{-n_a} \\ B(q^{-1}) &= b_1q^{-1} + b_2q^{-2} + \dots + b_{n_b}q^{-n_b} \\ C(q^{-1}) &= 1 + c_1q^{-1} + \dots + c_{n_c}q^{-n_c} \\ D(q^{-1}) &= d_0 + d_1q^{-1} + \dots + d_{n_d}q^{-n_d} \end{aligned} \quad (6.2)$$

V případě, že je systém znám, pak koeficienty polynomů $A(q^{-1}), B(q^{-1}), C(q^{-1}), D(q^{-1})$ mohou být spočítány ze spojitých parametrů systému. V případě, že systém je neznámý, je nutno koeficienty těchto polynomů určit měřením nebo pomocí metod pro odhad parametrů systému.

Rovnici (6.1) lze přepsat do následující formy

$$y(k) = \boldsymbol{\phi}^T(k) \hat{\boldsymbol{\theta}} + e(k) \quad (6.3)$$

kde $\boldsymbol{\theta}$ je vektor neznámých parametrů a je definován

$$\boldsymbol{\theta} = [a_1, \dots, a_{n_a}, b_1, \dots, b_{n_b}, d_0, \dots, d_{n_d}, c_1, \dots, c_{n_c}]^T \quad (6.4)$$

a $\boldsymbol{\phi}(k)$ je vektor dat (tzv. regresor), který obsahuje měřené vstupní a výstupní proměnné

$$\boldsymbol{\phi}^T(k) = [-y(k-1), \dots, -y(k-n_a), u(k-1), \dots, u(k-n_b), v(k-1), \dots, v(k-n_d), n(k-1), \dots, n(k-n_c)] \quad (6.5)$$

Vektor parametrů obsahuje také hodnoty neměřitelné poruchy. V této části předpokládejme že na systém nepůsobí náhodné poruchy tj. položíme $n_c = 0$ a tedy koeficienty polynomu $C(q^{-1})$ jsou nulové.

Předpokládejme, že rovnice (6.3), (6.4), (6.5) jsou exaktním popisem systému a tedy úkolem je určit z dostupného vektoru dat $\boldsymbol{\phi}(k)$ vektor parametrů $\boldsymbol{\theta}$. Za tímto účelem předpokládejme strukturu modelu systému:

$$y(k) = \boldsymbol{\phi}^T(k) \hat{\boldsymbol{\theta}} + \hat{e}(k) \quad (6.6)$$

kde $\hat{\boldsymbol{\theta}}$ je vektor nastavitelných parametrů modelu a $\hat{e}(k)$ je odpovídající chyba modelování v čase k . Cílem je zvolit $\hat{\boldsymbol{\theta}}$ tak, aby celková chyba modelování byla minimální.

Pokud máme naměřená data (předpokládejme počet N měření), rovnici (6.6) lze vyjádřit v následující vektorové/maticové formě:

$$\begin{bmatrix} y(1) \\ y(2) \\ \vdots \\ y(N) \end{bmatrix} = \begin{bmatrix} \boldsymbol{\phi}^T(1) \\ \boldsymbol{\phi}^T(2) \\ \vdots \\ \boldsymbol{\phi}^T(N) \end{bmatrix} \hat{\boldsymbol{\theta}} + \begin{bmatrix} \hat{e}(1) \\ \hat{e}(2) \\ \vdots \\ \hat{e}(N) \end{bmatrix} \quad (6.7)$$

Poznámka

Aby bylo možné určit parametry jednoznačně, musí být $N > n_a + (n_b + 1) + (n_d + 1)$. V případě že $\hat{e}(k) = 0$, je možné rovnici (6.7) řešit jako soustavu lineárních rovnic o m neznámých, kde $m = n_a + (n_b + 1) + (n_d + 1)$, výsledná chyba modelování je identicky rovna nule. V případě přítomnosti šumu (neměřitelné poruchy) musí být $N \gg m$ a k odhadu parametrů použít alternativní postup k redukci chyb odhadu způsobených přítomností šumu. Jednou z možností je použití metody nejmenších čtverců.

Přepíšme rovnici (6.7) na následující tvar

$$\mathbf{y} = \mathbf{F}\hat{\boldsymbol{\theta}} + \hat{\mathbf{e}} \quad (6.8)$$

kde

$$\begin{aligned} \mathbf{y}^T &= [y(1), \dots, y(N)] \\ \hat{\mathbf{e}}^T &= [\hat{e}(1), \dots, \hat{e}(N)] \end{aligned} \quad (6.9)$$

a

$$\mathbf{F} = \begin{bmatrix} \boldsymbol{\phi}^T(1) \\ \boldsymbol{\phi}^T(2) \\ \vdots \\ \boldsymbol{\phi}^T(N) \end{bmatrix} \quad (6.10)$$

z rovnice (6.8) lze vyjádřit chybový vektor $\hat{\mathbf{e}}$

$$\hat{\mathbf{e}} = \mathbf{y} - \mathbf{F}\hat{\boldsymbol{\theta}} \quad (6.11)$$

Zvolíme kritérium minimalizace kvadrátu odchylky

$$J = \hat{\mathbf{e}}^T \hat{\mathbf{e}} \rightarrow \min \quad (6.12)$$

které řešíme následovně

$$\begin{aligned}
\frac{\partial J}{\partial \hat{\boldsymbol{\theta}}} &= \frac{\partial (y - \mathbf{F}\hat{\boldsymbol{\theta}})^T}{\partial \hat{\boldsymbol{\theta}}} (y - \mathbf{F}\hat{\boldsymbol{\theta}}) + \frac{\partial (y - \mathbf{F}\hat{\boldsymbol{\theta}})^T}{\partial \hat{\boldsymbol{\theta}}} (y - \mathbf{F}\hat{\boldsymbol{\theta}}) = \\
&= -\mathbf{F}^T (y - \mathbf{F}\hat{\boldsymbol{\theta}}) - \mathbf{F}^T (y - \mathbf{F}\hat{\boldsymbol{\theta}}) = \\
&= -2\mathbf{F}^T (y - \mathbf{F}\hat{\boldsymbol{\theta}}) = 0
\end{aligned} \tag{6.13}$$

při použití vztahu

$$\frac{\partial (\mathbf{x}^T \mathbf{z})}{\partial \mathbf{a}} = \frac{\partial \mathbf{x}^T}{\partial \mathbf{a}} \mathbf{z} + \frac{\partial \mathbf{z}^T}{\partial \mathbf{a}} \mathbf{x} \tag{6.14}$$

Řešením dostaneme vektor odhadu parametrů $\hat{\boldsymbol{\theta}}$

$$\hat{\boldsymbol{\theta}} = (\mathbf{F}^T \mathbf{F})^{-1} \mathbf{F}^T \mathbf{y} \tag{6.15}$$

Pro rovnici (6.15) platí následující předpoklady:

1. Odhad $\hat{\boldsymbol{\theta}}$ je nevychýlený, když střední hodnota $\hat{\boldsymbol{\epsilon}}$ je nulová a $\hat{\boldsymbol{\epsilon}}$ je nekorelovaná s řádkami matice \mathbf{F} .
2. Když $E\{\hat{\boldsymbol{\epsilon}}\} = 0$, $Cov(\hat{\boldsymbol{\epsilon}}) = \sigma^2 \mathbf{I}$ a \mathbf{F} , jsou nekorelované, potom

$$Cov(\hat{\boldsymbol{\theta}}) = \sigma^2 (\mathbf{F}^T \mathbf{F})^{-1} \tag{6.16}$$

3. Když rozptyl σ^2 neznáme, můžeme ho odhadovat podle vztahu

$$\sigma^2 = \frac{1}{(N - M)} (\mathbf{y} - \mathbf{F}\hat{\boldsymbol{\theta}})^T (\mathbf{y} - \mathbf{F}\hat{\boldsymbol{\theta}}), \quad M = \max(n_a, n_b) \tag{6.17}$$

Matici $(\mathbf{F}^T \mathbf{F})^{-1}$ nazýváme kovarianční maticí a budeme ji dále označovat jako

C.

6.2 Rekurzivní metody identifikace

6.2.1 Rekurzivní metoda nejmenších čtverců (RLS)

Charakteristické rysy rekurzivní metody nejmenších čtverců:

- Je významnou součástí adaptivním systémů, kde daná akce je založena na aktuálním modelu.
- Požadavky na paměť počítače jsou malé, protože nevyžadují uchování všech naměřených hodnot.
- Je lehce modifikovatelná pro zpracování údajů v reálném čase a pro měnění se parametry.

Při odvození RMNČ předpokládáme, že známe odhad parametrů v kroku $k-1$ (staré hodnoty) a kovarianční matici $\mathbf{C}(k-1) = (\mathbf{F}^T(k-1)\mathbf{F}(k-1))^{-1}$. Úlohou je odvodit rekurzivní vztahy pro $\hat{\boldsymbol{\theta}}(k)$ a $\mathbf{C}(k)$. Když máme měření v kroku k , potom

$$\mathbf{F}(k) = \begin{bmatrix} \mathbf{F}(k-1) \\ \boldsymbol{\phi}^T(k) \end{bmatrix}, \quad \mathbf{F}^T(k) = [\mathbf{F}^T(k-1) \quad \boldsymbol{\phi}(k)] \quad (6.18)$$

$$\mathbf{y}(k) = \begin{bmatrix} \mathbf{y}(k-1) \\ y(k) \end{bmatrix} \quad (6.19)$$

odhad v kroku k

$$\hat{\boldsymbol{\theta}}(k) = (\mathbf{F}^T(k)\mathbf{F}(k))^{-1} \mathbf{F}^T(k)\mathbf{y}(k) \quad (6.20)$$

nyň

$$\begin{aligned} \mathbf{F}^T(k)\mathbf{F}(k) &= [\mathbf{F}^T(k-1) \quad \boldsymbol{\phi}(k)] \begin{bmatrix} \mathbf{F}(k-1) \\ \boldsymbol{\phi}^T(k) \end{bmatrix} \\ &= \mathbf{F}^T(k-1)\mathbf{F}(k-1) + \boldsymbol{\phi}^T(k)\boldsymbol{\phi}(k) \end{aligned} \quad (6.21)$$

z rovnice (6.18) a (6.19)

$$\begin{aligned} \mathbf{F}^T(k)\mathbf{y}(k) &= [\mathbf{F}^T(k-1) \quad \boldsymbol{\phi}(k)] \begin{bmatrix} \mathbf{y}(k-1) \\ y(k) \end{bmatrix} \\ \mathbf{F}^T(k)\mathbf{y}(k) &= \mathbf{F}^T(k-1)\mathbf{y}(k-1) + \boldsymbol{\phi}(k)y(k) \end{aligned} \quad (6.22)$$

označme

$$\begin{aligned} \mathbf{C}(k-1) &= [\mathbf{F}^T(k-1)\mathbf{F}(k-1)]^{-1} \\ \mathbf{B}(k-1) &= \mathbf{F}^T(k-1)\mathbf{y}(k-1) \end{aligned} \quad (6.23)$$

a tedy

$$\begin{aligned} \hat{\boldsymbol{\theta}}(k) &= \mathbf{C}(k)\mathbf{B}(k) \\ \hat{\boldsymbol{\theta}}(k-1) &= \mathbf{C}(k-1)\mathbf{B}(k-1) \end{aligned} \quad (6.24)$$

rovněž

$$\mathbf{C}^{-1}(k) = \mathbf{C}^{-1}(k-1) + \boldsymbol{\phi}(k)\boldsymbol{\phi}^T(k) \quad (6.25)$$

a

$$\mathbf{B}(k) = \mathbf{B}(k-1) + \boldsymbol{\phi}(k)y(k) \quad (6.26)$$

Rovnice (6.26) umožňuje přímou aktualizaci z $\mathbf{B}(k-1)$ na $\mathbf{B}(k)$. Rozhodující krok je zavést stejnou přímou aktualizaci z $\mathbf{C}(k-1)$ na $\mathbf{C}(k)$. Standardní způsob je aplikace věty o inverzi matice:

$$(\mathbf{A} + \mathbf{BCD})^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1}\mathbf{B}(\mathbf{C}^{-1} + \mathbf{DA}^{-1}\mathbf{B})^{-1}\mathbf{DA}^{-1}$$

na rovnici (6.25)

zavedme označení

$$\mathbf{A} = \mathbf{C}^{-1}(k-1), \quad \mathbf{C} = 1, \quad \mathbf{B} = \boldsymbol{\phi}(k), \quad \mathbf{D} = \boldsymbol{\phi}^T(k)$$

dostaneme

$$\mathbf{C}(k) = \mathbf{C}(k-1) \left[\mathbf{I}_m - \boldsymbol{\phi}(k)(1 + \boldsymbol{\phi}^T(k)\mathbf{C}(k-1)\boldsymbol{\phi}(k))^{-1}\boldsymbol{\phi}^T(k)\mathbf{C}(k-1) \right] \quad (6.27)$$

Rovnice (6.27) umožňuje aktualizaci $\mathbf{C}(k-1)$ na $\mathbf{C}(k)$ bez nutnosti počítat inverzi kovarianční matice.

Definujme odchylku $\hat{e}(k)$

$$\hat{e}(k) = y(k) - \boldsymbol{\phi}^T(k)\hat{\boldsymbol{\theta}}(k-1) \quad (6.28)$$

a dosadíme za $y(k)$ v rovnici (6.26) a dostaneme

$$\mathbf{B}(k) = \mathbf{B}(k-1) + \boldsymbol{\phi}(k)\boldsymbol{\phi}^T(k)\hat{\boldsymbol{\Theta}}(k-1) + \boldsymbol{\phi}(k)\hat{e}(k) \quad (6.29)$$

Dosazením za $\mathbf{B}(k-1)$, $\mathbf{B}(k)$ do rovnice (6.24) dostaneme

$$\hat{\boldsymbol{\Theta}}(k) = \hat{\boldsymbol{\Theta}}(k-1) + \mathbf{C}(k)\boldsymbol{\phi}(k)\hat{e}(k) \quad (6.30)$$

Formálně tedy můžeme zapsat rekurzivní metodu nejmenších čtverců následovně:

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

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

$$\hat{\boldsymbol{\Theta}}(k) = \hat{\boldsymbol{\Theta}}(k-1) + \mathbf{C}(k)\boldsymbol{\phi}(k)\hat{e}(k)$$

Algoritmus rekurzivní metody nejmenších čtverců (RLS) – verze 1:

V kroku k :

- 1) Naplnění vektoru $\boldsymbol{\phi}(k)$ novými daty

$$\boldsymbol{\phi}^T(k) = [-y(k-1), \dots, -y(k-n_a), u(k-1), \dots, u(k-n_b)]$$

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

- 3) $\mathbf{C}(k) = \mathbf{C}(k-1) - \frac{\mathbf{C}(k-1)\boldsymbol{\phi}(k)\boldsymbol{\phi}^T(k)\mathbf{C}(k-1)}{1 + \boldsymbol{\phi}^T(k)\mathbf{C}(k-1)\boldsymbol{\phi}(k)}$

- 4) $\hat{\boldsymbol{\Theta}}(k) = \hat{\boldsymbol{\Theta}}(k-1) + \mathbf{C}(k)\boldsymbol{\phi}(k)\hat{e}(k)$

- 5) opakuj krok 1

Odlišná formulace metody nejmenších čtverců:

Výraz $\mathbf{C}(k)\boldsymbol{\phi}(k)$ v rovnici (6.30) je vlastně korekční faktor (je to řádkový vektor). Můžeme navrhnout vektor $\mathbf{L}(k)$ tak, že platí

$$\mathbf{L}(k) = \mathbf{C}(k)\boldsymbol{\phi}(k) \quad (6.31)$$

takže

$$\hat{\boldsymbol{\theta}}(k) = \hat{\boldsymbol{\theta}}(k-1) + \mathbf{L}(k)\hat{e}(k) \quad (6.32)$$

kombinací rovnice (6.31) a výrazu pro $\mathbf{C}(k)$ (rovnice (6.27)), dostáváme rovnici pro výpočet $\mathbf{L}(k)$:

$$\mathbf{L}(k) = \frac{\mathbf{C}(k-1)\boldsymbol{\phi}(k)}{1 + \boldsymbol{\phi}^T(k)\mathbf{C}(k-1)\boldsymbol{\phi}(k)} \quad (6.33)$$

podobně, $\mathbf{C}(k)$ může být přepsáno jako

$$\mathbf{C}(k) = \mathbf{C}(k-1) - \mathbf{L}(k)\boldsymbol{\phi}^T(k)\mathbf{C}(k-1) \quad (6.34)$$

Algoritmus rekurzivní metody nejmenších čtverců (RLS) – verze 2:

V kroku k :

- 1) Naplnění vektoru $\boldsymbol{\phi}(k)$ novými daty

$$\boldsymbol{\phi}^T(k) = [-y(k-1), \dots, -y(k-n_a), u(k-1), \dots, u(k-n_b)]$$

- 2) $\hat{e}(k) = \mathbf{y}(k) - \boldsymbol{\phi}^T(k)\hat{\boldsymbol{\theta}}(k-1)$

- 3)
$$\mathbf{L}(k) = \frac{\mathbf{C}(k-1)\boldsymbol{\phi}(k)}{1 + \boldsymbol{\phi}^T(k)\mathbf{C}(k-1)\boldsymbol{\phi}(k)}$$

- 4)
$$\hat{\boldsymbol{\theta}}(k) = \hat{\boldsymbol{\theta}}(k-1) + \mathbf{L}(k)\hat{e}(k)$$

- 5)
$$\mathbf{C}(k) = \mathbf{C}(k-1) - \mathbf{L}(k)\boldsymbol{\phi}^T(k)\mathbf{C}(k-1)$$

- 6) opakuj krok 1

6.2.2 Modifikace základní rekurzivní metody nejmenších čtverců

Rekurzivní odhad parametrů diskutovaný výše byl zaměřen na určení konstantního vektoru parametrů. V mnoha případech je ale požadováno, aby bylo možno sledovat změny v množině parametrů. Tyto změny mohou být vyvolány změnou v provozním podmínkách (úroveň signálu, vnější podmínky, atd.), změnami vlastností surovin apod.

Identifikační algoritmy

Při použití klasické rekurzivní metody nejmenších čtverců dochází při konvergenci algoritmu ke značnému poklesu zesílení algoritmu (zesílení je funkcí kovarianční matice) až postupně k nulovým hodnotám, což způsobuje neschopnost sledovat změny v množině parametrů. Sledování časově proměnlivých parametrů může být zajištěno pomocí tzv. faktorů zapomínání, popř. pomocí přímé modifikace kovarianční matice. Tyto faktory zapomínání zabraňují přílišnému poklesu hodnot prvků kovarianční matice při konvergenci algoritmu a tak umožňují zajistit sledování časově proměnlivých parametrů. V této části budou uvedeny některé z nich.

a) Konstantní exponenciální zapomínání

Tomuto nastavení odpovídá kritérium

$$J = \sum_{i=1}^k \lambda^{k-i} \hat{\epsilon}_i^2 \quad (6.35)$$

Kovarianční matice

$$C(k) = \frac{1}{\lambda} \left(C(k-1) - \frac{C(k-1)\phi(k)\phi^T(k)C(k-1)}{\lambda + \phi^T(k)C(k-1)\phi(k)} \right) \quad (6.36)$$

Efekt λ spočívá v postupném zapomínání starších údajů, přičemž nejvyšší váha je na posledním měření. Tento typ identifikačního algoritmu je vhodný v případě, že se parametry systému pomalu mění.

Teoreticky je pro konvergenci parametrů nutné, aby se $\lambda=1$, ale zároveň požadujeme, aby byl algoritmus citlivý na změny parametrů (umožnil sledování změny

parametrů), což vyžaduje, aby $\lambda < 1$. Těmto dvěma protichůdným požadavkům vyhovuje proměnlivé faktory zapomínání. Jedním z nich je proměnlivé exponenciálního zapomínání.

b) Proměnlivé exponenciální zapomínání

Proměnlivé exponenciální zapomínání je dané vztahem

$$\lambda(k) = \lambda_0 \lambda(k-1) + 1 - \lambda_0 \quad (6.37)$$

a typické počáteční podmínky jsou

$$\lambda(0) = \lambda_0 \in \langle 0,95; 0,99 \rangle \quad (6.38)$$

Takto zvolené exponenciální zapomínání se asymptoticky blíží k 1 a tedy počáteční data jsou zapomenuta.

Tento typ identifikace se používá zejména pro stacionární systémy, protože zabraňuje příliš rychlému snižování zesílení a má za následek rychlou konvergenci, pokud jsou odhady parametrů ve velké vzdálenosti od optimálních.

c) Maticové exponenciální zapomínání

Předchozí uvedené způsoby zapomínání nejsou schopny zvládnout případy, kdy se hodnoty parametrů mění v čase rozdílnou rychlostí. Je to způsobeno tím, že stejná hodnota faktoru zapomínání (váha) je aplikována na všechny parametry. Maticové exponenciální zapomínání poskytuje každému z odhadovaných parametrů jinou váhu a tak umožňuje lepší sledování změn jednotlivých parametrů v čase.

$$\mathbf{A}(k-1) = \mathbf{\Omega} \mathbf{C}(k-1) \mathbf{\Omega}^T \quad (6.39)$$

zesílení je dáno vztahem

$$\mathbf{L}(k) = \frac{\mathbf{A}(k-1) \boldsymbol{\phi}(k)}{1 + \boldsymbol{\phi}^T(k) \mathbf{A}(k-1) \boldsymbol{\phi}(k)} \quad (6.40)$$

kovarianční matice

$$\mathbf{C}(k) = \mathbf{A}(k-1) \left(\mathbf{I} - \frac{\boldsymbol{\phi}(k) \boldsymbol{\phi}^T(k) \mathbf{A}(k-1)}{1 + \boldsymbol{\phi}^T(k) \mathbf{A}(k-1) \boldsymbol{\phi}(k)} \right) \quad (6.41)$$

kde

$$\mathbf{\Omega} = \begin{bmatrix} \frac{1}{\sqrt{\lambda_1}} & 0 & 0 \\ 0 & \ddots & 0 \\ 0 & 0 & \frac{1}{\sqrt{\lambda_n}} \end{bmatrix} \quad (6.42)$$

reprezentuje diagonální matici s elementy rovnými druhé odmocnině (jednotlivých) faktorů zapomínání odpovídajících jednotlivým prvkům regresního vektoru.

d) Směrové zapomínání (fixní a proměnlivé)

Rekurzivní metody s konstantním exponenciálním zapomínáním mají jednu nevýhodu. Pokud metoda nedostane delší čas nové informace ($\phi(k) = \phi(k-1)$), dojde k tomu, že hodnota kovarianční matice bude exponenciálně růst s faktorem λ , což může vést k numerické nestabilitě identifikačního algoritmu, a tím i k nestabilitě uzavřeného regulačního obvodu. Na zajištění stability byla vyvinuta metoda se směrovým zapomínáním, která zapomíná pouze v tom směru, ve kterém přišly nové informace. Rovnice popisující tuto metodu vypadají následovně:

$$\varepsilon(k-1) = \lambda' - \frac{1 - \lambda'}{\phi^T(k) \mathbf{C}(k-1) \phi(k)} \quad (6.43)$$

$$\mathbf{C}(k) = \mathbf{C}(k-1) - \frac{\mathbf{C}(k-1) \phi(k) \phi^T(k) \mathbf{C}(k-1)}{\varepsilon^{-1} + \phi^T(k) \mathbf{C}(k-1) \phi(k)} \quad (6.44)$$

kde λ' se volí stejně jako u exponenciálního zapomínání.

e) Adaptivní směrové zapomínání

$$\varepsilon(k) = \varphi(k) - \frac{1 - \varphi(k)}{\xi(k-1)} \quad (6.45)$$

kde

$$\xi(k-1) = \phi^T(k) \mathbf{C}(k-1) \phi(k)$$

hodnota adaptivního směrového zapomínání

$$\begin{aligned} \varphi(k) = & \left\{ 1 + (1 + \rho) \left[\ln(1 + \xi(k-1)) \right] + \right. \\ & \left. + \left[\frac{(\nu(k-1) + 1)\eta(k-1)}{1 + \xi(k-1) + \eta(k-1)} - 1 \right] \frac{\xi(k-1)}{1 + \xi(k-1)} \right\}^{-1} \end{aligned} \quad (6.46)$$

kde

$$\begin{aligned} \eta(k) &= \frac{\hat{e}^2(k)}{\lambda(k)} \\ \nu(k) &= \varphi(k) [\nu(k-1) + 1] \\ \lambda(k) &= \varphi(k) \left[\lambda(k-1) + \frac{\hat{e}^2(k-1)}{1 + \xi(k-1)} \right] \end{aligned}$$

f) Konstantní stopa

Tento algoritmus je založen na tom, že stopa kovarianční matice je udržována na konstantní hodnotě, čímž je zabráněno přílišnému nárůstu (zabránění vzniku wind-up efektu) a poklesu hodnot kovarianční matice (vypnutí algoritmu). Níže uvedený algoritmus kombinuje fixní exponenciální zapomínání spolu s udržováním konstantní stopy kovarianční matice.

$$\bar{\mathbf{C}}(k) = \frac{1}{\lambda} \left(\mathbf{C}(k-1) - \frac{\mathbf{C}(k-1)\boldsymbol{\phi}(k)\boldsymbol{\phi}^T(k)\mathbf{C}(k-1)}{\lambda + \boldsymbol{\phi}^T(k)\mathbf{C}(k-1)\boldsymbol{\phi}(k)} \right) \quad (6.47)$$

kde

$$\mathbf{C}(k) = c_1 \frac{\bar{\mathbf{C}}(k)}{\text{tr}(\bar{\mathbf{C}}(k))} + c_2 \mathbf{I} \quad (6.48)$$

a c_1 a c_2 jsou pozitivní (kladné) hodnoty dané vztahem

$$\frac{c_1}{c_2} = 10000, \quad \boldsymbol{\phi}^T(k)\boldsymbol{\phi}(k)c_1 \gg 1 \quad (6.49)$$

výše uvedený algoritmus se nazývá regularizovaný algoritmus konstantní stopy.

Další přístup k zlepšení chování spočívá v přímé modifikaci kovarianční matice C . Je zřejmé, že na její hlavní diagonále se nachází informace o rozptylu (neurčitosti) jednotlivých parametrů. Proto se v případě časově proměnných parametrů může zvětšit jejich rozptyl a tím zrychlit adaptaci kovarianční matice na nové podmínky.

$$C(k) = C(k) + \delta I \quad (6.50)$$

kde $\delta < 0,01$.

Další možné typy zapomínání používané pro zajištění sledování časově proměnlivých parametrů lze nalézt např. v [15], [30], [10], [42], [46]. Ve většině případů se jedná o kombinaci či zjednodušení výše uvedených faktorů zapomínání.

Kromě již uvedených variant rekurzivní metody nejmenších čtverců, existují ještě další modifikace, které více či méně zachovávají počáteční rychlost konvergence původního algoritmu a navíc poskytují vyšší stabilitu, popř. spolehlivější odhad parametrů např. [40], [20]. Jednou z modifikací je i tzv. EFRA algoritmus [43] (Exponential Forgetting and Resetting Algorithm), který umožňuje sledování časově proměnlivých parametrů a zároveň garantuje ohraničenost kovarianční matice.

EFRA (*Exponential Forgetting and Resetting Algorithm*)

$$\hat{\Theta}(k) = \hat{\Theta}(k-1) + \frac{\alpha C(k-1)\phi(k)}{\lambda + \phi^T(k)C(k-1)\phi(k)} \hat{e}(k)$$

$$C(k) = \frac{1}{\lambda} \left[C(k-1) - \frac{C(k-1)\phi(k)\phi^T(k)C(k-1)}{\lambda + \phi^T(k)C(k-1)\phi(k)} \right] + \beta I - \gamma C(k-1)^2$$

kde I je jednotková matice a α, β, γ jsou konstanty.

- $\sigma_{\min} I \leq C(k-1) \leq \sigma_{\max} I$ pro všechna k

$$\sigma_{\min} \approx \frac{\beta}{\alpha - \eta} \quad \sigma_{\max} \approx \frac{\eta}{\gamma} + \frac{\beta}{\eta} \quad \eta = \frac{1 - \lambda}{\lambda}$$

- $\alpha = 0.5, \beta = \gamma = 0.005$ a $\lambda = 0.95, \sigma_{\min} = 0.01$ a $\sigma_{\max} = 10$

Poznámka:

V případě, že se parametry mění náhle, je možné provádět cyklický restart kovarianční matice C na hodnotu αI , kde $\alpha \gg 1$ a tím zajistit sledování časově proměnlivých parametrů. Nevýhodou je ztráta naakumulovaná informace v okamžiku obnovy kovarianční matice.

6.2.3 *Rekurzivní metoda instrumentální proměnné (RIV)*

Lze dokázat, že pokud není reálný proces ovlivňován šumem takovým způsobem jak je předpokládáno u modelu ARX (šum prochází filtrem $1/A(q)$), odhady parametrů získané pomocí metody nejmenších čtverců jsou vychýlené a nekonzistentní. Základní myšlenka této metody je založena na modifikaci normálových rovnic.

Algoritmus rekurzivní metody instrumentální proměnné:

V kroku k :

- 1) Naplnění vektoru $\phi(k)$ novými daty, sestavení instrumentu $z(k)$

$$\phi^T(k) = [-y(k-1), \dots, -y(k-n_a), u(k-1), \dots, u(k-n_b)]$$

- 2) $\hat{e}(k) = y(k) - \phi^T(k)\hat{\theta}(k-1)$

- 3)
$$L(k) = \frac{C(k-1)z(k)}{1 + \phi^T(k)C(k-1)z(k)}$$

- 4) $\hat{\theta}(k) = \hat{\theta}(k-1) + L(k)\hat{e}(k)$

- 5) $C(k) = C(k-1) - L(k)\phi^T(k)C(k-1)$

- 6) opakuj krok 1

Volba instrumentální proměnné $z(k)$

- 1) Instrumentální proměnná nezávislá na modelu (typická volba)

$$z(k) = [u(k-1), \dots, u(k-n_a-n_b)]^T \quad (6.51)$$

- 2) Instrumentální proměnná závislá na modelu

$$z(k) = [-y_u(k-1), \dots, -y_u(k-n_a), u(k-1), \dots, u(k-n_b)]^T \quad (6.52)$$

kde

$$y_u(k) = \frac{\hat{B}(q^{-1}, k)}{\hat{A}(q^{-1}, k)} u(k) \quad (6.53)$$

Přesná realizace tohoto instrumentu by vyžadovala filtrovat všechny vstupní hodnoty přes aktuální model $\hat{B}(q^{-1}, k) / \hat{A}(q^{-1}, k)$, tzn. nepoužívat $y_u(k-i)$ pro $i > 0$ z předchozích rekurzí. Tento způsob realizace instrumentu je výpočetně náročný (roste lineárně s délkou dat).

Namísto toho, může být instrument generován pomocí následující diferencní rovnice a aktuálního odhadu parametrů:

$$y_u(k) = \hat{b}_1(k)u(k-1) + \dots + \hat{b}_{n_b}(k)u(k-n_b) - \hat{a}_1(k)y_u(k-1) - \dots - \hat{a}_{n_a}(k)y_u(k-n_a) \quad (6.54)$$

kde $y_u(k-i)$ pro $i > 0$ jsou použity z předchozích rekurzí.

Během několika prvních iterací rekurzivní metody instrumentální proměnné jsou odhady $\hat{a}_i(k)$ a $\hat{b}_i(k)$ nespolehlivé a proto se pro start této metody používá rekurzivní algoritmus nejmenších čtverců (prvních $4m$ iterací, kde $m = \max(n_a, n_b)$).

Výše uvedené modifikace rekurzivní metody nejmenších čtverců (pro sledování časově proměnných parametrů) jsou platné i pro rekurzivní metodu instrumentální proměnné.

6.2.4 Rozšířená rekurzivní metoda instrumentální proměnné (ERIV)

Tato metoda by měla zajistit zlepšení přesnosti a vyšší rychlost konvergence. Je založena na instrumentální proměnné, která má více prvků (hodnot) než je počet odhadovaných parametrů. Takto získaná přeúčtená soustava lineárních rovnic je řešena ve smyslu nejmenších čtverců.

Odvození algoritmu lze nalézt např. [18], [45].

$$\begin{aligned}
 \hat{\boldsymbol{\theta}}(k) &= \hat{\boldsymbol{\theta}}(k-1) + \mathbf{L}(k) \left(\mathbf{v}(k) - \boldsymbol{\Phi}^T(k) \hat{\boldsymbol{\theta}}(k-1) \right) \\
 \mathbf{L}(k) &= \mathbf{P}(k-1) \boldsymbol{\Phi}(k) \left(\boldsymbol{\Lambda}(k) + \boldsymbol{\Phi}^T(k) \mathbf{P}(k-1) \boldsymbol{\Phi}(k) \right)^{-1} \\
 \boldsymbol{\Phi}(k) &= \begin{bmatrix} \mathbf{w}(k) & \boldsymbol{\phi}(k) \end{bmatrix} \\
 \mathbf{w}(k) &= \mathbf{R}^T(k-1) \mathbf{z}(k) \\
 \boldsymbol{\Lambda}(k) &= \begin{bmatrix} -\mathbf{z}^T(k) \mathbf{z}(k) & 1 \\ 1 & 0 \end{bmatrix} \\
 \mathbf{v}(k) &= \begin{bmatrix} \mathbf{z}^T(k) \mathbf{r}(k-1) \\ \mathbf{y}(k) \end{bmatrix} \\
 \mathbf{R}(k) &= \mathbf{R}(k-1) + \mathbf{z}(k) \boldsymbol{\phi}^T(k) \\
 \mathbf{r}(k) &= \mathbf{r}(k-1) + \mathbf{z}(k) \mathbf{y}(k) \\
 \mathbf{P}(k) &= \mathbf{P}(k-1) - \mathbf{L}(k) \boldsymbol{\Phi}^T(k) \mathbf{P}(k-1)
 \end{aligned} \tag{6.55}$$

kde $n_z = \dim \mathbf{z} > \dim \boldsymbol{\phi} = \dim \boldsymbol{\theta}$, $n_{\boldsymbol{\theta}} = \dim \boldsymbol{\theta}$

Přesnost odhadu $\hat{\boldsymbol{\theta}}(k)$ roste se zvětšujícím se rozměrem vektoru instrumentální proměnné $\mathbf{z}(k)$.

Volba instrumentální proměnné může být provedena např. podle [9], [45].

6.2.5 Rozšířená rekurzivní metoda nejmenších čtverců (RELS)

U metody nejmenších čtverců je předpokládán model (ARX)

$$A(q^{-1})y(k) = B(q^{-1})u(k) + n(k) \quad (6.56)$$

V případě, že je výstup systému ovlivněn barevným šumem, je vhodnější model (ARMAX)

$$A(q^{-1})y(k) = B(q^{-1})u(k) + C(q^{-1})n(k) \quad (6.57)$$

kde, obecně, polynom $C(q^{-1})$ nemůže být považován za jednotkový. Samozřejmě je možné považovat $C(q^{-1})n(k)$ za „jednoduchou chybu“ a odhadovat pouze parametry polynomů $A(q^{-1}), B(q^{-1})$ pomocí RLS metody. Obecně, nicméně odhady získané tímto postupem budou vychýlené a nekonzistentní.

Za účelem odhadu parametrů polynomu $C(q^{-1})$ je nutná znalost hodnot $n(k-1), \dots, n(k-n_c)$. Nicméně, $\{n(k)\}$ je nepozorovatelná chyba procesu. Existuje mnoho metod pro odhadu parametrů, které nahrazují $n(k)$, zpravidla pomocí chyby predikce $\hat{e}(k)$ nebo residuí $\eta(k)$.

Poznámka:

Chyba predikce (a priori) $\hat{e}(k) = y(k) - \phi^T(k)\hat{\Theta}(k-1)$ je rozdíl mezi výstupem systému $y(k)$ a predikovaným výstupem za použití odhadu parametrů $\hat{\Theta}(k-1)$ z předchozího kroku $k-1$.

Residuum – skutečná chyba modelování (a posteriori) v kroku k je $\eta(k) = y(k) - \phi^T(k)\hat{\Theta}(k)$.

Jediný rozdíl mezi $\hat{e}(k)$ a $\eta(k)$ je v tom, že $\eta(k)$ je založena na odhadu parametrů $\hat{\Theta}(k)$ v aktuálním kroku k

Algoritmus rozšířené rekurzivní metody nejmenších čtverců (RELS) –verze 1:

V kroku k :

- 1) Naplnění vektoru $\phi(k)$ novými daty

$$\phi^T(k) = [-y(k-1), \dots, -y(k-n_a), u(k-1), \dots, u(k-n_b), \hat{e}(k-1), \dots, \hat{e}(k-n_c)]$$

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

- 3)
$$L(k) = \frac{C(k-1)\phi(k)}{1 + \phi^T(k)C(k-1)\phi(k)}$$

- 4) $\hat{\Theta}(k) = \hat{\Theta}(k-1) + L(k)\hat{e}(k)$

- 5) $C(k) = C(k-1) - L(k)\phi^T(k)C(k-1)$

- 6) opakuj krok 1

Algoritmus rozšířené rekurzivní metody nejmenších čtverců (RELS) –verze 2:

V kroku k :

- 1) Naplnění vektoru $\phi(k)$ novými daty

$$\phi^T(k) = [-y(k-1), \dots, -y(k-n_a), u(k-1), \dots, u(k-n_b), \eta(k-1), \dots, \eta(k-n_c)]$$

- 2) $\eta(k-1) = y(k-1) - \phi^T(k-1)\hat{\Theta}(k-1)$

- 3)
$$L(k) = \frac{C(k-1)\phi(k)}{1 + \phi^T(k)C(k-1)\phi(k)}$$

- 4) $\hat{\Theta}(k) = \hat{\Theta}(k-1) + L(k)\hat{e}(k)$

- 5) $C(k) = C(k-1) - L(k)\phi^T(k)C(k-1)$

- 6) opakuj krok 1

6.2.6 Rekurzivní metoda predikčních chyb (RPEM)

Tato metoda umožňuje rekurzivně odhadovat parametry všech výše uvedených modelů. Protože některé z těchto modelů jsou nelineární v parametrech, neexistuje exaktní rekurzivní algoritmus, a proto musí být použito aproximací ([19], [35], [34], [45]). Na metodu predikčních chyb může být nahlíženo jako na nelineární Gauss-Newtonovu metodu nejmenších čtverců.

Gauss-Newtonova metoda je založena na aproximaci Hessovy matice (matice druhých derivací) pomocí gradientů. Takže, rekurzivní metoda predikčních chyb vyžaduje výpočet gradientů ztrátové funkce, což vyžaduje výpočet gradientu ($\boldsymbol{\psi}(k)$) výstupu prediktoru modelu (protože gradient $\hat{e}^2(k) = (y(k) - \hat{y}(k))^2$ je $-2e(k)\partial\hat{y}(k)/\partial\boldsymbol{\Theta}$) podle jednotlivých parametrů.

$$\boldsymbol{\psi}(k) = \frac{\partial\hat{y}(k)}{\partial\boldsymbol{\Theta}(k)} = \left[\frac{\partial\hat{y}(k)}{\partial\Theta_1(k)} \quad \frac{\partial\hat{y}(k)}{\partial\Theta_2(k)} \quad \dots \quad \frac{\partial\hat{y}(k)}{\partial\Theta_n(k)} \right]^T \quad (6.58)$$

Algoritmus rekurzivní metody predikčních chyb má pak tvar:

$$\begin{aligned} \hat{e}(k) &= y(k) - \boldsymbol{\phi}^T(k)\hat{\boldsymbol{\Theta}}(k-1) \\ \mathbf{L}(k) &= \frac{\mathbf{P}(k-1)\boldsymbol{\psi}(k)}{1 + \boldsymbol{\psi}^T(k)\mathbf{P}(k-1)\boldsymbol{\psi}(k)} \\ \hat{\boldsymbol{\Theta}}(k) &= \hat{\boldsymbol{\Theta}}(k-1) + \mathbf{L}(k)\hat{e}(k) \\ \mathbf{P}(k) &= \mathbf{P}(k-1) - \mathbf{L}(k)\boldsymbol{\psi}^T(k)\mathbf{P}(k-1) \end{aligned}$$

Struktura modelu ovlivňuje způsob, jakým se určuje $\boldsymbol{\psi}(k)$ z naměřených dat a vypočtených předchozích odhadů parametrů.

Metoda RPEM pro model ARMAX

optimální prediktor je dán vztahem ([31], [38], [45])

$$\hat{y}(k|k-1) = \frac{B(q^{-1})}{C(q^{-1})}u(k) + \left(1 - \frac{A(q^{-1})}{C(q^{-1})}\right)y(k) \quad (6.59)$$

pro chybu predikce je možno psát

$$\hat{e}(k) = \frac{A(q^{-1})}{C(q^{-1})}y(k) - \frac{B(q^{-1})}{C(q^{-1})}u(k) \quad (6.60)$$

kde jednotlivé polynomy mají následující tvar

$$\begin{aligned} A(q^{-1}) &= 1 + a_1q^{-1} + \dots + a_{n_a}q^{-n_a} \\ B(q^{-1}) &= b_1q^{-1} + b_2q^{-2} + \dots + b_{n_b}q^{-n_b} \\ C(q^{-1}) &= 1 + c_1q^{-1} + \dots + c_{n_c}q^{-n_c} \end{aligned} \quad (6.61)$$

Poznámka:

Prediktor pro model ARMAX je stabilní dokonce i když polynom $A(q^{-1})$ je nestabilní a tudíž i model ARMAX je nestabilní. Nicméně, pro stabilitu prediktoru je nezbytné, aby polynom $C(q^{-1})$ byl stabilní.

Určení gradientu

vynásobíme rovnici (6.59) polynomem $C(q)$

$$C(q^{-1})\hat{y}(k|k-1) = B(q^{-1})u(k) + (C(q^{-1}) - A(q^{-1}))y(k) \quad (6.62)$$

derivace (6.62) podle a_i je

$$C(q^{-1})\frac{\partial \hat{y}(k|k-1)}{\partial a_i} = -y(k-i) \quad (6.63)$$

po úpravě dostaneme

$$\frac{\partial \hat{y}(k|k-1)}{\partial a_i} = -\frac{1}{C(q^{-1})}y(k-i) \quad (6.64)$$

derivace (6.62) podle b_i je

$$C(q^{-1}) \frac{\partial \hat{y}(k|k-1)}{\partial b_i} = u(k-i) \quad (6.65)$$

po úpravě dostaneme

$$\frac{\partial \hat{y}(k|k-1)}{\partial b_i} = \frac{1}{C(q^{-1})} u(k-i) \quad (6.66)$$

derivace (6.62) podle c_i je

$$\hat{y}(k-i|k-i-1) + C(q^{-1}) \frac{\partial \hat{y}(k|k-1)}{\partial c_i} = y(k-i) \quad (6.67)$$

po úpravě dostaneme

$$\frac{\partial \hat{y}(k|k-1)}{\partial c_i} = \frac{1}{C(q^{-1})} (y(k-i) - \hat{y}(k-i|k-i-1)) = \frac{1}{C(q^{-1})} \hat{e}(k-i) \quad (6.68)$$

Takže gradient může být snadno spočítán filtrací regresorů $y(k-i)$, $u(k-i)$ a $\hat{e}(k-i)$ pomocí lineárního filtru $1/C(q^{-1})$.

$$\begin{aligned} y^F(k-i) &= \frac{1}{C(q^{-1})} y(k-i) \\ u^F(k-i) &= \frac{1}{C(q^{-1})} u(k-i) \\ \hat{e}^F(k-i) &= \frac{1}{C(q^{-1})} \hat{e}(k-i) \end{aligned} \quad (6.69)$$

Gradient je tedy možno psát ve tvaru

$$\boldsymbol{\psi}(k) = \begin{bmatrix} -y^F(k-1) \dots -y^F(k-n_a) & u^F(k-1) \dots u^F(k-n_b) \\ \hat{e}^F(k-1) \dots \hat{e}^F(k-n_c) \end{bmatrix}^T \quad (6.70)$$

pro filtrované hodnoty lze psát

$$\begin{aligned} y^F(k) &= y(k) - \hat{c}_1(k)y^F(k-1) - \dots - \hat{c}_n(k)y^F(k-n_c) \\ u^F(k) &= u(k) - \hat{c}_1(k)u^F(k-1) - \dots - \hat{c}_n(k)u^F(k-n_c) \\ \hat{e}^F(k) &= \hat{e}(k) - \hat{c}_1(k)\hat{e}^F(k-1) - \dots - \hat{c}_n(k)\hat{e}^F(k-n_c) \end{aligned} \quad (6.71)$$

kde pro chybu predikce platí

$$\begin{aligned} \hat{e}(k) &= y(k) + \hat{a}_1(k-1)y(k-1) + \dots + \hat{a}_{n_a}(k-1)y(k-n_a) \\ &\quad - \hat{b}_1(k-1)u(k-1) - \dots - \hat{b}_{n_b}(k-1)u(k-n_b) \\ &\quad - \hat{c}_1(k-1)\hat{e}(k-1) - \dots - \hat{c}_{n_c}(k-1)\hat{e}(k-n_c) \end{aligned} \quad (6.72)$$

Uvedené rovnice lze mírně upravit tak, že k výpočtu $\hat{e}(k)$ se místo hodnot parametrů v kroku $(k-1)$ použijí hodnoty aktuálního odhadu parametrů $\hat{\Theta}(k)$. Označíme-li predikční chybu, která je počítána z aktuálních hodnot parametrů jako $\eta(k)$, lze tedy psát

$$\begin{aligned} \hat{e}(k) &= y(k) + \hat{a}_1(k-1)y(k-1) + \dots + \hat{a}_{n_a}(k-1)y(k-n_a) \\ &\quad - \hat{b}_1(k-1)u(k-1) - \dots - \hat{b}_{n_b}(k-1)u(k-n_b) \\ &\quad - \hat{c}_1(k-1)\eta(k-1) - \dots - \hat{c}_{n_c}(k-1)\eta(k-n_c) \end{aligned} \quad (6.73)$$

kde

$$\begin{aligned} \eta(k) &= y(k) + \hat{a}_1(k)y(k-1) + \dots + \hat{a}_{n_a}(k)y(k-n_a) \\ &\quad - \hat{b}_1(k)u(k-1) - \dots - \hat{b}_{n_b}(k)u(k-n_b) \\ &\quad - \hat{c}_1(k)\eta(k-1) - \dots - \hat{c}_{n_c}(k)\eta(k-n_c) \end{aligned} \quad (6.74)$$

a gradient je určen vztahem

$$\begin{aligned} \boldsymbol{\psi}(k) &= \left[-y^F(k-1) \dots - y^F(k-n_a) \quad u^F(k-1) \dots u^F(k-n_b) \right. \\ &\quad \left. \eta^F(k-1) \dots \eta^F(k-n_c) \right]^T \end{aligned} \quad (6.75)$$

filtrovaná hodnota $\eta(k)$ je

$$\eta^F(k) = \eta(k) - \hat{c}_1(k)\eta^F(k-1) - \dots - \hat{c}_n(k)\eta^F(k-n) \quad (6.76)$$

Metoda RPEM pro model OE

Optimální prediktor pro model OE

$$\hat{y}(k|k-1) = \hat{y}(k) = \frac{B(q^{-1})}{F(q^{-1})}u(k) = w(k) \quad (6.77)$$

chyba predikce je dána

$$\hat{e}(k) = y(k) - \frac{B(q^{-1})}{F(q^{-1})}u(k) \quad (6.78)$$

kde jednotlivé polynomy mají následující tvar

$$\begin{aligned} B(q^{-1}) &= b_1q^{-1} + b_2q^{-2} + \dots + b_{n_b}q^{-n_b} \\ F(q^{-1}) &= 1 + f_1q^{-1} + \dots + f_{n_f}q^{-n_f} \end{aligned} \quad (6.79)$$

Poznámka:

Optimální prediktor pro model OE je ve skutečnosti simulátor, protože nevyžaduje hodnoty výstupu procesu. Také lze vynechat značení " $|k-1$ ", protože optimální predikce pro tento model není založena na předchozích hodnotách výstupů procesu.

Určení gradientu

vynásobíme rovnici (6.77) polynomem $F(q^{-1})$

$$F(q^{-1})\hat{y}(k) = B(q^{-1})u(k) \quad (6.80)$$

derivace (6.80) podle b_i je

$$F(q^{-1})\frac{\partial \hat{y}(k)}{\partial b_i} = u(k-i) \quad (6.81)$$

po úpravě dostaneme

$$\frac{\partial \hat{y}(k)}{\partial b_i} = \frac{1}{F(q^{-1})}u(k-i) \quad (6.82)$$

derivace (6.80) podle f_i je

$$\hat{y}(k-i) + F(q^{-1}) \frac{\partial \hat{y}(k)}{\partial f_i} = 0 \quad (6.83)$$

po úpravě dostaneme

$$\frac{\partial \hat{y}(k)}{\partial f_i} = -\frac{1}{F(q^{-1})} \hat{y}(k-i) \quad (6.84)$$

Takže gradient může být snadno určen filtrací regresorů $\hat{y}(k-i)$, $u(k-i)$ pomocí lineárního filtru $1/F(q^{-1})$. Označíme-li $w(k) = \hat{y}(k)$, můžeme psát

$$\begin{aligned} u^F(k-i) &= \frac{1}{F(q^{-1})} u(k-i) \\ w^F(k-i) &= \frac{1}{F(q^{-1})} w(k-i) \end{aligned} \quad (6.85)$$

Gradient je tedy možno psát ve tvaru

$$\boldsymbol{\psi}(k) = \left[u^F(k-1) \dots u^F(k-n_b) \quad -w^F(k-1) - \dots - w^F(k-n_c) \right]^T \quad (6.86)$$

pro filtrované hodnoty lze psát

$$\begin{aligned} u^F(k) &= u(k) - \hat{c}_1(k)u^F(k-1) - \dots - \hat{c}_n(k)u^F(k-n) \\ w^F(k) &= w(k) - \hat{c}_1(k)w^F(k-1) - \dots - \hat{c}_n(k)w^F(k-n) \end{aligned} \quad (6.87)$$

Odvození výpočtu gradientu pro obecný lineární model (4.1) lze nalézt např. v [31], [38], [10].

Poznámka:

Pro odhad parametrů modelu OE lze použít i metodu nejmenších čtverců kde vektor dat bere v úvahu výstup modelu namísto reálného výstupu. Metoda je podobná metodě instrumentální proměnné.

Pro model OE lze psát

$$\begin{aligned} w(k) &= b_1 u(k-1) + \dots + b_{n_b} u(k-n_b) \\ &\quad - f_1 w(k-1) - \dots - f_{n_f} w(k-n_f) \\ y(k) &= w(k) + n(k) \end{aligned} \quad (6.88)$$

Vektor dat a parametrů jsou pak dány

$$\hat{\boldsymbol{\theta}}(k) = [b_1, \dots, b_{n_b}, f_1, \dots, f_{n_f}] \quad (6.89)$$

$$\boldsymbol{\phi}^T(k) = [u(k-1), \dots, u(k-n_a), -w(k-1), \dots, w(k-n_b)] \quad (6.90)$$

vnitřní proměnná $w(k)$ je nepozorovatelná a proto je pouze odhadovaná ze vztahu

$$w(k) = \frac{\hat{B}(q^{-1}, k)}{\hat{F}(q^{-1}, k)} u(k) \quad (6.91)$$

Přesná realizace by vyžadovala filtrovat všechny vstupní hodnoty přes aktuální model. Tento způsob realizace je výpočetně náročný (roste lineárně s délkou dat).

Namísto toho, může být vnitřní proměnná $w(k)$ generována pomocí následující diferenciální rovnice a aktuálních odhadů parametrů:

$$\begin{aligned} w(k) &= \hat{b}_1(k) u(k-1) + \dots + \hat{b}_{n_b}(k) u(k-n_b) \\ &\quad - \hat{f}_1(k) w(k-1) - \dots - \hat{f}_{n_f}(k) w(k-n_f) \end{aligned} \quad (6.92)$$

6.3 Inicializace rekurzivního algoritmu

S výše uvedenými metodami průběžné identifikace je spojena problematika volby vhodných počátečních podmínek pro start algoritmu. Jedná se především o volbu počátečních odhadů vektoru parametrů, počátečních hodnot kovarianční matice a vhodného faktoru zapomínání.

6.3.1 Volba počátečních odhadů vektoru parametrů

Start rekurzivního algoritmu vyžaduje určení počáteční odhadů vektoru parametrů $\hat{\Theta}(0)$. Existuje několik možností, jak volit tyto počáteční odhady. V případě, že máme dostatek informací o identifikovaném objektu, nepředstavuje volba počátečního odhadu žádný problém. Ve většině případů, však apriorní informace chybí nebo je nedostačující a v takovém případě lze považovat za vhodnou volbu nastavení nulových hodnot počátečních odhadů.

6.3.2 Počáteční nastavení kovarianční matice

Kovarianční matice $C(k)$ vyjadřuje míru neurčitosti neznámých parametrů systému. Pokud nejsou k dispozici žádné apriorní znalosti vztahující se k parametrům systému, je vhodné volit "velké" hodnoty na diagonále kovarianční matice. V případě, že jsou počáteční parametry blízké skutečným parametrům systému, je vhodné volit "malé" hodnoty na diagonále kovarianční matice.

6.3.3 Volba faktoru zapomínání

Je zřejmé, že existuje celá řada faktorů zapomínání. Každý z uvedených faktorů má svá omezení. Volba faktoru zapomínání je vždy kompromisem mezi zachováním schopnosti sledování a schopností konvergence. Velká hodnota faktoru zapomínání znamená pomalejší sledování změn parametrů, ale vyšší odolnost proti působícímu šumu a naopak malá hodnota zapomínání má za následek vyšší rychlost adaptace algoritmu při změnách parametrů, ale nižší odolnost proti působícímu šumu.

7 ADAPTIVNÍ ŘÍZENÍ

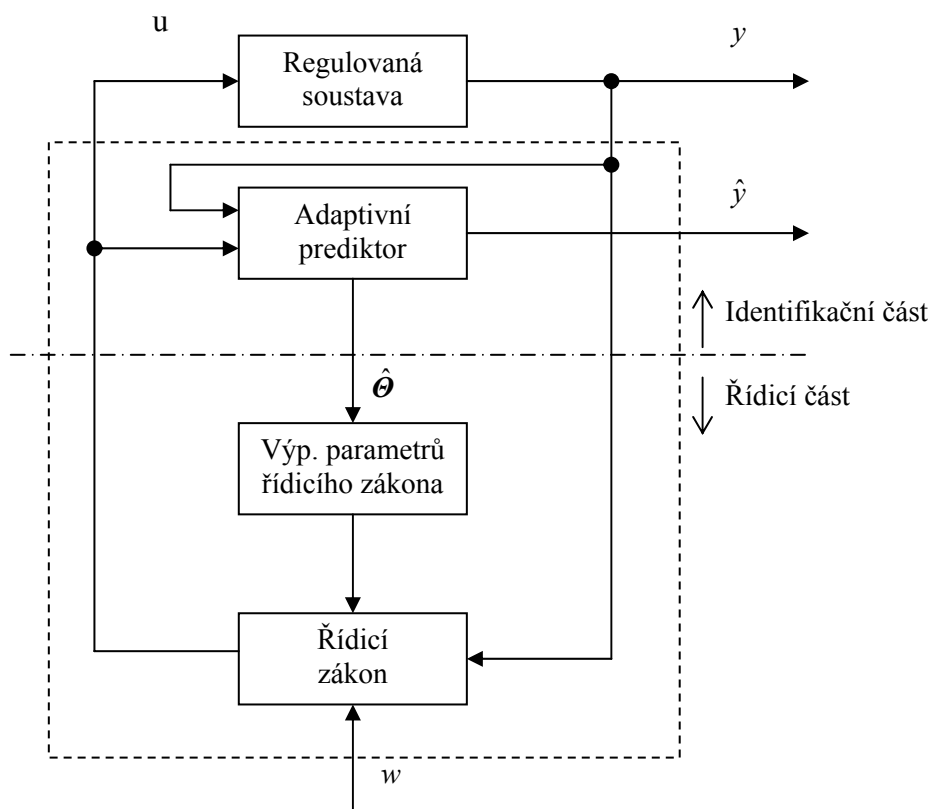
Převážná většina procesů, se kterými se v praxi setkáváme má, má stochastický charakter. Klasické regulátory s pevně nastavenými parametry pro řízení takových procesů často nevyhovují, neboť při změnách parametrů procesu je řízení neoptimální a dochází ke ztrátám materiálu, energie, snižování životnosti zařízení atd. Změna parametrů procesu je způsobena změnami v provozních režimech, změnami vlastností surovin, paliva, zařízení (stárnutím), se kterými se pevně seřízené regulátory nemohou vyrovnat.

Jednou z možností zvýšení kvality řízení takových procesů je použití adaptivních systémů, které jsou schopny se vyrovnat i se značně nepříznivými podmínkami, díky své přizpůsobivosti pružně reagují na změny v regulovaných systémech.

Jednou třídou adaptivních řídicích systémů jsou samočinně se nastavující regulátory (*Self-Tuning Controllers* – STC), které jsou založeny na průběžném odhadování vlastností soustavy a poruch, postupném upřesňování a tím i sledování možných změn. Na základě dosažené znalosti lze vhodnými metodami navrhnout optimální regulátor.

7.1 Samočinně se nastavující regulátory (STC)

STC regulátory používají prakticky tytéž algoritmy jako pevně nastavené regulátory, ale navíc obsahují průběžnou identifikaci. Algoritmická struktura STC regulátoru je znázorněna na Obr. 7.1.



Obr. 7.1: Algoritmická struktura samočinně se nastavujícího regulátoru

Princip těchto regulátorů spočívá v tom, že se v každém kroku regulace provádí identifikace soustavy. Výsledné odhady parametrů slouží k syntéze regulátoru. Z teorie odhadů parametrů je však známo, že tyto odhady jsou vždy zatíženy určitou chybou. Tato neurčitost závisí např. na počtu identifikačních kroků, na volbě struktury matematického modelu řízeného procesu, průběhu akčních veličin či periodě vzorkování. Proto hraje identifikace důležitou roli při poznávání dynamických a statických vlastností řízeného procesu. Aby bylo možno soustavu správně identifikovat a získat o ní maximum informací, je nutné volit takový akční zásah, který musí splňovat určité podmínky. Ale současně je potřeba zajistit takový akční zásah, aby se regulovaná veličina co nejvíce blížila žádané hodnotě. Jelikož se zde řeší dva problémy (problém identifikace a problém řešení požadované přesnosti výstupů vůči žádané hodnotě), nazývá se toto řízení duální. Návrh optimálního řízení je předložen v [14]. Protože takto navržené řízení má dvojitý účinek, nazývá se optimální duální řízení. Vzhledem ke komplexnosti výpočtů nezbytných pro

návrh exaktního optimální duální řízení je použití tohoto postupu v mnoha případech příliš náročné. Pro řešení daného problému, bylo navrženo několik zjednodušujících přístupů. Jedním z nejúčinnějších postupů je tzv. metoda bikriteriální syntézy pro duální adaptivní regulátor [16].

Dalším přístupem je řešení dané úlohy zjednodušeně na základě experimentálních zkušeností a intuice, jak je uvedeno [6], [7]. Toto řešení se nazývá vnucená separace identifikace řízení.

7.1.1 Algoritmy identifikace pro samočinně se nastavující regulátory


Z hlediska identifikace parametrů zvoleného modelu není třeba rozlišovat parametry a_i , b_i , c_i či f_i , ale pracujeme s vektorem neznámých parametrů $\Theta(k)$ a vektorem dat $\phi(k-1)$.

Pro účely řízení prostřednictvím samočinně se nastavujících regulátorů nás zajímají pouze ty způsoby experimentální identifikace, které můžeme realizovat v reálném čase. Pro odhadování parametrů v reálném čase jsou nejvhodnější průběžné (rekurzivní) procedury, kde odhady v kroku k se získají tak, že novými daty opravíme staré odhady $\hat{\Theta}(k-1)$ v čase $k-1$.

V identifikační části samočinně se nastavujícího regulátoru mohou být pro získání odhadu parametrů odpovídajících modelů použity rekurzivní identifikační metody popsané v kapitole 6.

8 PARALELNÍ ZAPOJENÍ REKURZIVNÍCH IDENTIFIKAČNÍCH ALGORITMŮ

Samočinně se nastavující regulátory jsou založeny na rekurzivním odhadu parametrů řízeného systému. Získané parametry jsou následně použity pro syntézu regulátoru. Přítomnost neměřitelných poruch a příliš jednoduchý model, který dostatečně nevystihuje dynamiku řízeného systému, mohou způsobit, že jednoduché rekurzivní identifikační schéma (tzn. že v okamžicích vzorkování běží pouze jediný rekurzivní identifikační algoritmus) neposkytuje dostatečně spolehlivé odhady parametrů a navržený regulátor proto nemusí spolehlivě pracovat. Jednou z možností zvýšení spolehlivosti a výkonu samočinně se nastavujícího regulátoru spočívá v nahrazení jednoduchého identifikačního algoritmu složitější strukturou, která je založena na paralelním běhu několika rekurzivních identifikačních algoritmů.



Obr. 8.1: Paralelní multiestimační schéma

V další části budeme tedy uvažovat uzavřený regulační obvod s paralelním zapojením adaptivních regulátorů a odpovídajících rekurzivních identifikačních metod, jehož struktura je uvedena na Obr. 8.1. Regulátory mohou být obecně stejného nebo typu různého.

Princip výše uvedeného zapojení lze popsat následujícím způsobem: V identifikační části samočinně se nastavujícího regulátoru běží paralelně N_e rekurzivních identifikačních algoritmů (v každém okamžiku vzorkování t_k vrací každý z rekurzivních identifikačních algoritmů vektor odhadu parametrů $\hat{\theta}_i(k)$ a predikci výstupu modelu $\hat{y}_i(k)$, kde $i \in K = \{1, 2, \dots, N_e\}$, taktéž může samozřejmě každý z identifikačních algoritmů poskytovat i další informace o svém chování např. kovarianční matici, vektor dat apod. za účelem sledování chování odhadu parametrů). Jednotlivé identifikační algoritmy mohou být obecně stejného nebo různého typu lišící se různými počátečními hodnotami vektoru odhadu parametrů a tvoří tzv. paralelní multiestimační schema. V obvodu se také nachází N_e adaptivních regulátorů (v každém čase je pouze jeden z nich připojen k řízenému systému) takže i -tý adaptivní regulátor je parametrizován v každém časovém okamžiku t_k odpovídajícím i -tým rekurzivním identifikačním algoritmem. Na každý pár adaptivní regulátor - identifikační algoritmus, se tedy lze odkazovat pomocí indexu $i \in K$. Označme jako c_k hodnotu, která definuje regulátor (parametrizovaný jeho odpovídajícím identifikačním algoritmem), který je aktivní (tj. připojený k řízenému systému za účelem řízení) v čase t_k . Výběr aktuálního regulátoru z N_e regulátorů, který bude použit k vygenerování akčního zásahu pro řízený systém se provádí v nadřazeném členu a je založen na vyhodnocování zvoleného kritéria, které zahrnuje chybu predikce $\hat{e}_i(k) = y(k) - \hat{y}_i(k)$ jednotlivých identifikačních algoritmů a zohledňuje velikost změny výstupu systému způsobené jednotlivými regulátory.

8.1 Nadřazený člen

Úspěšná aplikace adaptivního řízení vyžaduje, aby byly splněny předpoklady, na základě kterých byl odvozen princip adaptivního parametrického řízení, odhad parametrů a návrh regulátoru.

Při řízení reálného procesu může dojít k tomu, že tyto a priori předpoklady nebudou splněny z důvodu očekávaných nebo neočekávaných změn v provozních (pracovních) podmínkách řízeného procesu nebo adaptivního uzavřeného obvodu. Nedodržení těchto předpokladů může mít za následek nepřijatelné (nevhodné) nebo nestabilní chování parametrického adaptivního regulátoru. Proto je nezbytné trvale monitorovat několik funkcí adaptivního uzavřeného obvodu.

Kromě již výše zmíněné činnosti (tj. výběru vhodného aktivního regulátoru), je nadřazený člen použit také pro sledování jednotlivých funkcí adaptivního uzavřeného obvodu a vyhodnocování jejich chování. Jeho úkolem je detekovat nevhodné změny v chování těchto funkcí a následně se snažit zajistit případnou nápravu.

V souvislosti se strukturou zapojení uvedenou na Obr. 8.1 můžeme tedy úkoly nadřazeného členu rozdělit do 4 základních úrovní:

1. Start adaptivního regulátoru.
2. Monitorování jednotlivých procedur pro odhadu parametrů (vypínání/zapínání odhadu, filtrace odhadu parametrů, restart identifikačního algoritmu).
3. Monitorování návrhu jednotlivých adaptivních regulátorů (stabilita uzavřeného regulačního obvodu, výběr pouze těch regulátorů, které stabilizují uzavřený regulační obvod).
4. Výběr aktivního regulátoru (ze všech možných regulátorů), který bude použit pro vygenerování akčního zásahu.

Jednotlivé body budou podrobněji rozebrány v následujících kapitolách.

Nadřazený člen může být samozřejmě navržen více způsoby. Každá realizace a aplikace nadřazeného členu může být odlišná a záleží na očekávaném přínosu, náročnosti na výpočetní čas a také záměru, se kterým byl nadřazený člen vytvářen.

8.1.1 Start adaptivního regulátoru

Samočinně se nastavující regulátory (STC) jsou založeny na průběžném odhadování parametrů neznámého procesu. Před startem STC musí být tedy vybrána vhodná rekurzivní metoda identifikace pro odhad neznámých parametrů procesu a provedena její inicializace (volba stupňů jednotlivých polynomů, počáteční hodnota kovarianční matice a vektoru odhadu parametrů, perioda vzorkování, faktor zapomínání a velikost dopravního zpoždění), poté je možno zahájit adaptivní režim regulátoru. Nicméně v důsledku nedostatečné znalosti parametrů procesu a působícího šumu, může dojít k nepředvídatelnému chování v podobě rozkmitu (růstu a poklesu) hodnot akční a regulované veličiny.

Lepší start adaptivního regulátoru může být zajištěn vhodným vybuzením procesu pomocí přesně stanoveného budícího vstupního signálu (např. PNBS) pro definovaný časový úsek. Pro stabilní procesy je možno provádět identifikaci na základě dat získaných z otevřeného obvodu, pro procesy na hranici stability nebo nestabilní je identifikace prováděna z dat získaných z uzavřeného regulačního obvodu (s připojeným regulátorem, např. P regulátorem). Tímto způsobem získáme před samotným přepnutím na adaptivní režim vhodné parametry modelu, čímž můžeme eliminovat počáteční rozkmit akční a regulované veličiny.

Přepnutí z této předběžné identifikace na adaptivní režim může být také provedeno automaticky na základě vyhodnocení vhodného kritéria.

Vhodná kritéria jsou:

- nejméně $2m + d + 1$ kroků
- konvergence identifikační metody

$$\text{tr}\mathbf{C}^{-1}(k + (2m + d + 1)) - \text{tr}\mathbf{C}^{-1}(k) < \kappa_1, \text{ kde } \kappa_1 \text{ je zvolená konstanta}$$

- porovnání výstupu modelu a procesu

$$\frac{1}{N} \sum_{k=1}^N [y(k) - \hat{y}(k)] < \kappa_2, \text{ kde } \kappa_2 \text{ je zvolená konstanta}$$

Kde m značí celkový počet odhadovaných parametrů, d je počet kroků dopravního zpoždění.

8.1.2 Monitorování odhadu parametrů

Hlavním cílem monitorování odhadu parametrů je zajistit, aby dynamické chování získaného modelu procesu adekvátně odpovídalo chování systému reálného. Kromě samotného monitorování odhadu parametrů jsou nezbytné i další činnosti, jako je vypínání odhadu parametrů, filtrace odhadů a restart identifikačního algoritmu.

Dále budou v této části uvedeny některé příčiny, které mohou mít za následek, že odhady parametrů poskytnuté identifikačním algoritmem nebudou dostatečně vystihovat dynamické chování procesu, což může mít za následek nevhodné chování uzavřeného obvodu a také možné způsoby zmírnění popř. eliminace takto vniklých problémů.

8.1.2.1 Nedostatek trvalé excitace

Jednou ze základních podmínek spolehlivé funkce identifikačního algoritmu je nutnost trvalého buzení objektu. Základní funkcí regulačního obvodu je, aby regulovaná veličina dosáhla žádané hodnoty, popř. se pohybovala okolo žádané hodnoty. V důsledku ustálení lineárního řídicího zákona dochází k malým změnám externích veličin, můžou vznikat dlouhé periody bez buzení, kdy není k dispozici nová informace, čímž roste neurčitost parametrů. Neurčitost parametrů může vést k numerické nestabilitě identifikačního algoritmu. Tento fakt je zvláště patrný při použití konstantního exponenciálního zapomínání. Při dlouhých periodách bez dostatečného buzení, kdy není k dispozici nová informace, způsobuje exponenciální zapomínání v těchto podmínkách ztrátu starší informace, čímž roste neurčitost parametrů. Kovarianční matice exponenciálně narůstá, což má za následek růst zesílení identifikačního algoritmu. V takové situaci při příchodu nové informace dochází k prudkým změnám – nestabilitě v odhadovaných parametrech. Konečným důsledkem v uzavřeném obvodu je potom nestabilita obvodu. Tento jev je znám pod názvem "bursting", je způsobovaný konstantní hodnotou

exponenciálního zapomínání $\lambda < 1$. Tento jev se může v uzavřeném obvodu cyklicky opakovat, neboť vzniklá nestabilita obvodu může být z hlediska identifikace chápána jako buzení, výsledkem kterého může být konvergence algoritmu k novým ustáleným hodnotám odhadovaných parametrů. Následné ustálení regulačního zákona a obvodu může potom při zřídkačném buzení vést k opakování tohoto jevu.

Uvedenému problému můžeme předcházet několika způsoby. Společným rysem je úsilí o to, aby matice C zůstávala ohraničená:

- Konstantní stopa matice [11] – v tomto případě je stopa kovarianční matice udržována na konstantní hodnotě, což zajišťuje konstantní hodnotu zesílení identifikačního algoritmu.
- Směrové zapomínání [27], [29], [47] – zabraňuje přílišnému nárůstu kovarianční matice při nedostatečné excitaci.
- Proměnlivý faktor zapomínání [17]– velikost faktoru zapomínání se mění v závislosti na velikosti chyby predikce (zmenšující se hodnota chyby predikce má za následek nárůst faktoru zapomínání a naopak rostoucí hodnota chyby predikce způsobuje jeho pokles).
- Pomocný budící signál [48] – přidáváním pomocného budícího signálu o daných vlastnostech na vstupu systému má za následek zlepšení vlastností odhadu parametrů.
- Další způsoby např. tzv. EFRA algoritmus [43].

Jedno z dalších možných řešení, jak zabránit vzniku numerické nestability algoritmu, spočívá ve vypnutí rekurzivního algoritmu v případě nedostatečného buzení. Detekce úrovně vybuzení může být prováděna na základě vyhodnocování informačního obsahu dat, chování kovarianční matice (popř. informační matice), popř. průběhu výstupního signálu. Další možností je vypínání algoritmu identifikace na základě sledování průběhu chyby predikce, průběhu parametrů (za předpokladu, že změna hodnot odhadu parametrů je dostatečně malá, můžeme předpokládat, že došlo k ustálení hodnot odhadu parametrů a v tom případě je algoritmus identifikace vypnut - to má také za následek hladší průběh regulované veličiny a akčního zásahu).

Vypnutí algoritmu na základě vyhodnocení informačního obsahu dat:

$$J_i < eps, \quad J_i = \boldsymbol{\phi}_i^T(k) \mathbf{C}_i(k-1) \boldsymbol{\phi}_i(k) \quad (8.1)$$

Kde eps značí práh rozhodování., $\boldsymbol{\phi}_i(k)$ je vektor dat a $\mathbf{C}_i(k-1)$ je kovarianční matice i -tého identifikačního algoritmu. Při splnění uvedené podmínky dojde k vypnutí daného algoritmu identifikace.

Vypnutí algoritmu na základě chování kovarianční matice

V tomto případě je algoritmus identifikace vypnut, pokud kovariační matice \mathbf{C}_i není pozitivně definitní (tj. některé z vlastních čísel je ≤ 0), popř. stopa kovarianční matice překročí určitou zvolenou hodnotu.

Vypnutí algoritmu na základě vyhodnocení průběhu chyby predikce:

$$J_i < eps, \quad J_i = \frac{1}{M} \sqrt{\sum_{j=k-M}^k [\hat{e}_i(j) - \bar{e}_i]^2}, \quad \bar{e}_i = \frac{1}{M} \sum_{j=k-M}^k \hat{e}_i(j) \quad (8.2)$$

V případě splnění uvedeného kritéria dojde k vypnutí i -tého identifikačního algoritmu, kde eps značí práh rozhodování a M je počet posledních hodnot, ze kterých je kritérium počítáno.

Vypnutí algoritmu na základě vyhodnocení průběhu regulované veličiny:

$$J < eps, \quad J = \frac{1}{M} \sqrt{\sum_{j=k-M}^k [y(j) - \bar{y}]^2}, \quad \bar{y} = \frac{1}{M} \sum_{j=k-M}^k y(j) \quad (8.3)$$

Ustálení regulovaného výstupu je posuzováno na základě směrodatné odchylky. Jednotlivé algoritmy rekurzivní identifikace jsou poté vypnuty, když je splněna podmínka (8.3), kde eps značí práh rozhodování a M je počet posledních hodnot, ze kterých je kritérium počítáno.

Vypnutí algoritmu na základě vyhodnocení průběhu parametrů přenosu soustavy:

Můžeme předpokládat, že v případě ustálení parametrů dojde i k ustálení regulované veličiny a akčního zásahu, což může vést k nedostatečnému buzení systému. V tomto případě je tedy vhodné algoritmus identifikace vypnout.

$$J_i < eps, \quad J_i = \max_r \frac{1}{M} \sqrt{\sum_{j=k-M}^k [\hat{\boldsymbol{\theta}}_{ir}(j) - \bar{\boldsymbol{\theta}}_{ir}]^2}, \quad \bar{\boldsymbol{\theta}}_{ir} = \frac{1}{M} \sum_{j=k-M}^k \hat{\boldsymbol{\theta}}_{ir}(j) \quad (8.4)$$

V tomto případě vyhodnocujeme maximální směrodatnou odchylku ze všech parametrů, kde ϵ značí práh rozhodování, M je počet posledních hodnot, ze kterých je kritérium počítáno a $\hat{\theta}_{ir}(j)$ představuje hodnotu r -tého parametru i -tého identifikačního algoritmu v j -tém kroku

Výše uvedená kritéria mohou být také použita k opětovnému zapnutí algoritmu identifikace na základě nesplnění podmínek v jednotlivých kritériích.

8.1.2.2 Rychlé změny vlastností procesu

Náhlé změny vlastností procesu nebo velké a náhlé změny v pracovním bodě v případě nelineárního systému mohou mít za následek, že získání korektních hodnot odhadu parametrů lineárního modelu procesu bude obtížné.

V rámci nadřazeného členu je možné sledovat hodnoty chyby predikce, její rozptyl a ztrátovou funkci. V případě, že tyto hodnoty překročí určitou hranici, je vhodné provést redukci (zmenšení) faktoru zapominání dokud se tyto hodnoty nevrátí do daných mezí [17].

Pro velmi rychlé a velké změny ve vlastnostech procesu je dokonce možné, že navzdory redukci faktoru zapominání a velkým hodnotám chyby predikce bude adaptace odhadů parametrů probíhat příliš pomalu. V tomto případě je vhodné provést přímou modifikaci kovariační matice [47], [42], [25], což má za následek urychlení konvergence.

8.1.2.3 Filtrace odhadu parametrů

V důsledku vlivu šumu na odhad parametrů může dojít k tomu, že hodnoty odhadu parametrů obvykle oscilují. Z tohoto důvodu je vhodné provádět filtraci parametrů modelu procesu, která má za následek hladší průběh vypočítaných parametrů regulátoru a také vygenerovaného akčního zásahu

$$\hat{\theta}_f(k) = \kappa \hat{\theta}_f(k-1) + (1-\kappa) \hat{\theta}_f(k-1) \quad 0 \leq \kappa < 1 \quad (8.5)$$

nebo lze k výpočtu filtrovaných odhadů využít následující vztah

$$\hat{\theta}_f(k) = \frac{1}{M} \sum_{j=k-M}^{k-1} \hat{\theta}(j) \quad (8.6)$$

Poznámka:


Další možností zlepšení odhadu parametrů spočívá v nahrazení chyby predikce $\hat{e}(k) = y(k) - \phi^T(k)\hat{\Theta}(k-1)$, funkcí $f(\hat{e}(k))$, která redukuje účinek působení velkých náhlých změn v neměřitelných signálech ovlivňujících odhadované parametry. K těmto velkým řídkým změnám dochází např. v případě občasného selhání sensorů. Funkce $f(\hat{e}(k))$ je pro malé hodnoty chyby predikce lineární funkcí, ale pro velké hodnoty chyby predikce narůstá pomalu [11].

8.1.3 Monitorování návrhu regulátoru

Kromě monitorování procedury pro odhad parametrů, je vhodné dohlížet také na návrh regulátoru. Monitorování výpočtu regulátoru pomáhá zlepšovat bezpečnost adaptivního uzavřeného obvodu a omezit vliv rychlých a častých změn parametrů regulátoru na regulační obvod.

8.1.3.1 Adaptivní LQ regulátor

Adaptivnost klade na regulátor jisté požadavky. Je-li však zvládnuta spolehlivá identifikace, je možno pro syntézu regulátoru použít klasické algoritmy, jako jsou regulace s minimálním či konečným počtem kroků, úloha přiřazení pólů, apod.



Obr. 8.2: Blokové schéma regulačního obvodu s regulátorem se dvěma stupni volnosti

Pro návrh regulátoru je využito algebraického přístupu. Jedná se o regulátor se dvěma stupni volnosti (viz. Obr. 8.2), který je založený na minimalizaci kvadratického kritéria s penalizací akční veličiny (8.7) – LQ regulátor.

$$J = \sum_{k=0}^{\infty} \left\{ [w(k) - y(k)]^2 + q_u [u(k)]^2 \right\} \quad (8.7)$$

kde $w(k)$ je žádaná hodnota, $y(k)$ je regulovaná veličina (výstup řízeného systému), $u(k)$ je akční veličina (výstup regulátoru) a q_u je tzv. penalizační konstanta, která udává podíl akční veličiny na hodnotě kritéria ($q_u \geq 0$).

Minimalizace uvedeného kritéria je realizována pomocí spektrální faktorizace pro vstupně výstupní popis soustavy.

V další části bude uveden pouze výsledný algoritmus regulátoru pro dané polynomy přenosu soustavy a regulátoru bez nároku na jeho odvození. Odvození algoritmu, včetně určení stupňů jednotlivých polynomů regulátoru, lze nalézt v [8].

Předpokládejme soustavu s přenosem 2. řádu, tj. polynom čitatele a jmenovatele přenosu soustavy má tvar $A(z^{-1}) = 1 + a_1 z^{-1} + a_2 z^{-2}$, $B(z^{-1}) = b_1 z^{-1} + b_2 z^{-2}$. Polynomy regulátoru jsou pak dány následovně $P(z^{-1}) = p_0 z^{-1} + p_1 z^{-2}$, $Q(z^{-1}) = q_0 + q_1 z^{-1} + q_2 z^{-2}$,

$R(z^{-1}) = r_0 = \frac{1 + d_1 + d_2 + d_3 + d_4}{b_1 + b_2}$, $K(z^{-1}) = 1 - z^{-1}$. Jednotlivé koeficienty polynomů

regulátorů jsou pak dány řešením následující diofantické rovnice $A(z^{-1})K(z^{-1})P(z^{-1}) + B(z^{-1})Q(z^{-1}) = D(z^{-1})$, kde polynom pravé strany diofantické rovnice má tvar $D(z^{-1}) = 1 + d_1 z^{-1} + d_2 z^{-2} + d_3 z^{-3} + d_4 z^{-4}$.

Algoritmus řízení založený na minimalizaci kvadratického kritéria obsahuje následující kroky:

- 1) Výpočet parametrů pomocného polynomu $M(z^{-1})$

$$m_0 = q_u (1 + a_1^2 + a_2^2) + b_1^2 + b_2^2 \quad m_1 = q_u (a_1 + a_1 a_2) + b_1 b_2 \quad m_2 = q_u a_2$$

2) Vypočet parametrů polynomu $D(z^{-1})$

$$\lambda = \frac{m_0}{2} - m_2 \sqrt{\left(\frac{m_0}{2} + m_2\right)^2 - m_1^2} \quad \delta = \frac{\lambda + \sqrt{\lambda^2 - 4m_2^2}}{2}$$

$$d_1 = \frac{m_1}{\delta + m_2} \quad d_2 = \frac{m_2}{\delta} \quad d_3 = d_4 = 0$$

3) Vypočítají se parametry regulátoru ($p_0 = 1$) řešením maticové rovnice

$$\begin{bmatrix} b_1 & 0 & 0 & 1 \\ b_2 & b_1 & 0 & a_1 - 1 \\ 0 & b_2 & b_1 & a_2 - a_1 \\ 0 & 0 & b_2 & -a_2 \end{bmatrix} \begin{bmatrix} q_0 \\ q_1 \\ q_2 \\ p_1 \end{bmatrix} = \begin{bmatrix} d_1 + 1 - a_1 \\ d_2 + a_1 - a_2 \\ d_3 + a_2 \\ d_4 \end{bmatrix}$$

4) Řídicí zákon je dán následující diferenční rovnicí

$$u(k) = r_0 w(k) - q_0 y(k) - q_1 y(k-1) - q_2 y(k-2) + (1 - p_1)u(k-1) + p_1 u(k-2)$$

V souvislosti s uvažovaným schématem uvedeným na Obr. 8.1 je zřejmé, že místo hodnot koeficientů polynomů A_i, B_i ($i \in K$) jsou do jednotlivých rovnic dosazovány jejich odhady získané v každém kroku pomocí rekurzivní identifikace a tedy v každém kroku jsou na základě takto získaných odhadů parametrů i -tého modelu určovány parametry polynomů $Q_i(z^{-1}), P_i(z^{-1}), R_i(z^{-1})$ odpovídajícího i -tého regulátoru pomocí výše uvedeného postupu. V každém kroku tedy máme určeny parametry N_e regulátorů a můžeme pro každý z regulátorů vypočítat hodnotu jeho výstupu, zbývá pouze určit způsob, jakým bude volen aktuální regulátor, tj. ten který je připojen k řízenému systému za účelem řízení.

8.1.3.2 Stabilita uzavřeného regulačního obvodu

Z výše uvedeného vyplývá, že v každém kroku máme k dispozici N_e regulátorů. Regulátor musí být především navržen tak, aby uzavřený regulační obvod byl stabilní, tzn. že před samotným zařazením indexu odpovídajícímu danému páru adaptivní regulátor – identifikační algoritmus do množiny L (obsahuje indexy dvojic stabilní regulátor – identifikační algoritmus) je nezbytné provést test stability uzavřeného obvodu s

jednotlivými regulátory. V případě, že je uzavřený obvod s daným regulátorem nestabilní, nebude index charakterizující tuto i -tou dvojici adaptivní regulátor – identifikační algoritmus do množiny L zařazen a bude proveden restart odpovídající i -té identifikace.

O průběhu regulačního pochodu (zejména o jeho stabilitě) rozhoduje především jmenovatel přenosu řízení.

$$G_w = \frac{Y(z)}{W(z)} = \frac{B(z^{-1})R(z^{-1})}{A(z^{-1})K(z^{-1})P(z^{-1}) + B(z^{-1})Q(z^{-1})} \quad (8.8)$$

Matematicky lze podmínku stability uzavřeného regulačního obvodu formulovat požadavkem, aby charakteristická rovnice uzavřeného regulačního obvodu měla pouze stabilní kořeny (póly), tj. aby $|z_i| < 1 \quad i = 1, 2, \dots, n$.

8.1.4 Volba aktivního regulátoru

V této části bude objasněno, jakým způsobem je volen aktuální adaptivní regulátor (tj. ten regulátor, který bude aktivní v čase t_k) z množiny paralelních regulátorů tak, aby průběh přechodového děje, který vzniká při přepínání mezi jednotlivými regulátory, byl akceptovatelný. Adaptivní regulátor je reparametrizován odpovídajícím identifikačním algoritmem ve vhodných časových okamžicích. Nadřazený člen na základě vyhodnocení zvoleného kritéria (tzv. ukazatele jakosti) provádí volbu aktivní dvojice adaptivní regulátoru – identifikační algoritmus a určuje časy přepínání mezi jednotlivými vybranými odpovídajícími dvojicemi adaptivní regulátor - identifikační algoritmus.

Vyhodnocování se provádí na základě následujícího kritéria:

$$J_i(k) = \alpha_k \sum_{\ell=k-M}^k \lambda(\ell)^{k-\ell} (y(\ell) - \hat{y}_i(\ell))^2 + \beta_k (\hat{y}_{c_{k-1}}(k+1) - \hat{y}_i(k+1))^2 \quad (8.9)$$

kde

$$\hat{y}_{c_{k-1}}(k+1) = \begin{bmatrix} -y(k) & -y(k-1) & \dots & -y(k-n+1) \\ u_{c_{k-1}}(k) & u(k-1) & \dots & u(k-n+1) \end{bmatrix} \hat{\theta}_{c_{k-1}}(k) \quad (8.10)$$

Hodnota $\hat{y}_{c_{k-1}}(k+1)$ udává hodnotu jednokrokové predikce výstupu modelu řízeného systému při působení regulátoru, který je v kroku k aktivní. $\hat{\theta}_{c_{k-1}}(k)$ je vektor odhadu parametrů modelu řízeného systému. Odhad parametrů $\hat{\theta}_{c_{k-1}}(k)$ je získáván v každém kroku k pomocí odpovídající rekurzivní identifikační metody, která je dána právě aktivní dvojicí adaptivní regulátor-identifikační algoritmus.

a

$$\hat{y}_i(k+1) = \begin{bmatrix} -y(k) & -y(k-1) & \dots & -y(k-n+1) \\ u_i(k) & u(k-1) & \dots & u(k-n+1) \end{bmatrix} \hat{\theta}_i(k) \quad (8.11)$$

Hodnota $\hat{y}_i(k+1)$ určuje hodnotu jednokrokové predikce výstupu i -tého modelu řízeného systému, jestliže by došlo v kroku k k přepnutí na odpovídající i -tý regulátor (tj. stala by se aktivní i -tá dvojice adaptivní regulátor-identifikační algoritmus). $\hat{\theta}_i(k)$ je vektor odhadu parametrů i -tého modelu řízeného systému v kroku k . Odhad parametrů $\hat{\theta}_i(k)$ je získáván v každém kroku k na základě odpovídající rekurzivní identifikační metody, která je dána i -tou dvojicí adaptivní regulátor-identifikační algoritmus.

Hodnota $c_k \in L$ udává dvojici adaptivní regulátor - identifikační algoritmus, která je aktivní v kroku k . M je celé číslo, dostatečně veliké, aby dané kritérium dávalo smysl. Veličina $y(\ell)$ představuje hodnotu výstupu řízeného systému v kroku ℓ (kde $\ell = (k-M)$ až k) a $\hat{y}_i(\ell)$ udává hodnotu predikce výstupu i -tého modelu řízeného systému v kroku ℓ (kde $\ell = (k-M)$ až k).

Kritérium sestává ze dvou částí. První část $(\alpha_k \sum_{\ell=k-M}^k \lambda(\ell)^{k-\ell} (y(\ell) - \hat{y}_i(\ell))^2)$ je mírou přesnosti každého z daných identifikačních algoritmů, kde $\lambda(\ell)$ je faktor zapomínání (který, může být proměnlivý v závislosti na čase). Druhá část $(\beta_k (\hat{y}_{c_{k-1}}(k+1) - \hat{y}_i(k+1))^2)$ umožňuje posoudit vliv velikosti změny výstupu řízeného systému způsobené připojením daného regulátoru na jeho vstup. V případě, že přepnutí

mezi dvěma regulátory by způsobilo prudkou změnu výstupu řízeného systému, tak k přepnutí buď nedojde nebo se provede přepnutí na regulátor, který je blíže aktuálnímu regulátoru (tj. ten který je připojen k řízenému systému), čímž se zabrání přílišným změnám výstupu řízeného systému. Váhy α_k, β_k udávají podíl každého ze členů na celkovou hodnotu kritéria a jsou voleny tak, že platí $\alpha_k, \beta_k \geq 0, \alpha_k + \beta_k = 1 \quad \forall k \geq 0$

Přepínání mezi jednotlivými regulátory se děje následujícím způsobem. Označme sekvenci časů přepínání $\{t_1, t_2, \dots, t_\pi\}$ (kde π je počet přepnutí), pak identifikátor c_{N_i} , který udává aktivní dvojici adaptivní regulátor – identifikační algoritmus v čase $t_i = N_i T_0$, kde $i = 1, 2, \dots, \pi$ je určen vztahem

$$c_{N_i} \in \left\{ j \in L \mid J_j(N_i) = \min \{ J_r(N_i), r \in L \} \right\} \quad (8.12)$$

kde sekvence časů přepínání je taková, že platí $t_{i+1} - t_i \geq \tau_D$, kde τ_D je prodleva mezi časy přepnutí, zavedená z důvodu zajištění stability. Požadavek časové prodlevy mezi jednotlivými přepnutími je nezbytná podmínka pro zajištění stability uzavřeného obvodu. Když se regulátor stane aktivním v čase t_k , tak musí být v činnosti nejméně do času $t_k + \tau_D$. Pak, jestliže ukazatel jakosti sdružený s jiným možným regulátorem je menší než u aktivního regulátoru, může systém provést přepnutí na tento regulátor.

Hodnota indexu c udávajícího aktivní dvojici adaptivní regulátor – identifikační algoritmus je mezi dvěma přepnutími konstantní (tj. pro všechna celá čísla $\ell \in \{N_i, \dots, N_{i+1} - 1\}$, je zobrazení c konstantní pro všechna $t \in [t_i, t_{i+1})$ $c_\ell = c_{N_i}$ a tedy stejný identifikační algoritmus parametrizuje daný adaptivní regulátor.

9 SIMULAČNÍ OVĚŘENÍ

9.1 Popis integrovaného vývojového prostředí MATLAB a SIMULINK

MATLAB je integrované prostředí pro vědeckotechnické výpočty, modelování, simulace, prezentaci a analýzu dat.

Jádrem MATLABu jsou algoritmy pro operace s maticemi komplexních čísel. MATLAB umožňuje provádět běžné operace jako násobení, inverze, determinant atd. a v nejjednodušší podobě jej lze použít jako maticový kalkulátor, protože všechny tyto operace se zapisují téměř tak, jako bychom je psali na papíře. Vektor reálných čísel může v MATLABu reprezentovat i polynom a operace s polynomy jsou v programu rovněž obsaženy. Vektory také mohou reprezentovat časové řady nebo signály a MATLAB obsahuje funkce pro jejich analýzu, jako je hledání extrémů, výpočet střední hodnoty, směrodatné odchylky a korelační koeficienty nebo rychlou Fourierovu transformaci. Součástí MATLABu je i programovací jazyk, který je daleko jednodušší než např. Fortran nebo C. Tento jazyk skýtá obrovský potenciál produktivity a tvořivosti.

MATLAB má široké možnosti ve zobrazování a prezentaci výsledků. Je možné kreslit různé druhy grafů: dvourozměrné, třírozměrné, histogramy, apod. MATLAB také umožňuje otevřít více oken pro zobrazení více grafů v jednom okně. Každému objektu v okně je přiřazen identifikátor, jehož prostřednictvím je možné měnit vlastnosti objektu a tím i jeho vzhled.

Otevřená architektura MATLABu vedla ke vzniku knihoven funkcí, nazývaných toolboxy, které rozšiřují jeho použití v příslušných vědních a technických oborech. Tyto knihovny jsou napsané v převážné míře v jazyku MATLABu a nabízejí předzpracované specializované funkce, které je možno rozšiřovat, modifikovat, anebo jen čerpat informace z přehledně dokumentovaných algoritmů.

Control System Toolbox je aplikační knihovna, která rozšiřuje systém MATLAB o nástroje pro řídicí techniku a teorii systémů. Funkce z oblasti analýzy a návrhu řídicích

systemů využívají jak klasické přechodové charakteristiky, tak i popisy systémů ve stavovém prostoru.

SIMULINK je program pro simulaci a modelování dynamických systémů, který využívá algoritmy MATLABu pro numerické řešení nelineárních diferenciálních rovnic. Poskytuje možnost snadno a rychle vytvářet modely dynamických soustav ve formě blokových schémat a rovnic. Pomocí SIMULINKu a jeho grafického editoru lze vytvářet modely lineárních, nelineárních, v čase diskretních nebo spojitých systémů pouhým přesouváním funkčních bloků myší. SIMULINK také umožňuje spouštět některé části simulačního schématu na základě výsledku logické podmínky. Knihovnu SIMULINKu je možno snadno rozšiřovat o uživatelské bloky. Vlastnosti bloků lze nastavovat i přímo z okna MATLABu formou volání m-funkcí, což je zvláště vhodné při přípravě počátečních podmínek. Bloky mohou být i prosté m - funkce nebo tzv. s - funkce.


Pomocí menu SIMULINKu lze nastavit parametry simulace, jako je doba simulace, algoritmus řešení diferenciálních rovnic a tedy tím ovlivňovat běh simulačního experimentu. Vývoj simulace můžeme sledovat přímo v jejím průběhu. Výsledná data lze uložit do souboru nebo do proměnné v MATLAB Workspace.

9.2 Model pro simulační ověřování

Výše navržené paralelní multiestimační schéma, bylo otestováno při adaptivním řízení lineárního modelu s proměnlivými parametry. Řízený systém je modelován jako systém 2.řádu. Model řízeného systému sestává z deterministické a stochastické části a má následující tvar:

$$G_d(s) = \frac{s+k}{(T_1s+1)(T_2s+1)}, \quad G_s(s) = \frac{s+1}{(10s+1)(5s+1)} \quad (9.1)$$
$$G(s) = G_d(s) + G_s(s)$$

kde $G_d(s)$ značí přenosovou funkci deterministické části modelu řízeného procesu, $G_s(s)$ je přenosová funkce stochastické části modelu řízeného procesu a $G(s)$ celkový přenos řízeného systému. Blokové schéma modelu řízeného systému je uvedeno na následujícím obrázku (viz. Obr. 9.1)



Obr. 9.1: Blokové schéma řízeného systému

Průběh změn parametrů řízeného systému (k, T_1, T_2) je popsán v následující tabulce (viz. **Tabulka 1**)

Tabulka 1 – Průběh změny parametrů modelu řízeného systému.

k	T_1	T_2	časový interval
1	10	5	$0 \leq t \leq 100, 600 \leq t \leq 700$
0,8	8	5	$100 \leq t \leq 200, 700 \leq t \leq 800$
0,6	7	4	$200 \leq t \leq 300, 800 \leq t \leq 900$
0,8	6	5	$300 \leq t \leq 400, 900 \leq t \leq 1000$
0,8	5	4	$400 \leq t \leq 500, 1000 \leq t \leq 1100$
1	8	6	$500 \leq t \leq 600, 1100 \leq t \leq 1200$

Z výše uvedeného popisu je zřejmé, že ve zvolených časových okamžicích (každých 100 s) dochází k náhlým změnám parametrů řízeného systému.

Výsledné multiestimační schéma (viz. Obr. A.1) je sestaveno ze 7 různých rekurzivních identifikačních algoritmů (a jim odpovídajících adaptivních regulátorů) běžících paralelně. Seznam (včetně pořadí) těchto algoritmů je uveden v tabulce (viz. **Tabulka 2**).

Všechny adaptivní regulátory použité v jednotlivých dvojicích estimátor-adaptivní regulátor v uvedeném schématu jsou stejného typu, jedná se o adaptivní LQ regulátor, jehož popis je uveden v kapitole 8.1.3.1.

Počáteční hodnoty vektoru odhadu parametrů pro jednotlivé rekurzivní identifikační algoritmy byly nastaveny následujícím způsobem:

$$\text{RLS, RIV1, RIV2, RPLR-OE, RPEM-OE: } \hat{\theta}^T(0) = [0.1, 0.2, 0.3, 0.4]$$

$$\text{RPLR-ARMAX, RPEM-ARMAX: } \hat{\theta}^T(0) = [0.1, 0.2, 0.3, 0.4, 0.5, 0.6]$$

Pro zajištění sledování časově proměnlivých parametrů, jsou do jednotlivých rekurzivních identifikačních algoritmů implementovány tzv. faktory zapomínání. V našem případě se jedná o adaptivní směrové zapomínání. Počáteční hodnoty faktoru zapomínání

jsou nastaveny pro všechny uvedené rekurzivní identifikační algoritmy následovně:
 $\varphi(0)=1, \rho(0)=0.99, \nu(0)=10^{-6}, \lambda(0)=0.001$.

Perioda vzorkování $T_0 = 3s$ a prodleva mezi jednotlivými přepnutími $N_D = 2$ jsou shodné pro všechny provedené simulační experimenty. Hloubka paměti M , váhy α_k, β_k a faktor zapomínání λ_k pro vyhodnocování kritéria (8.9) jsou pro jednotlivé provedené experimenty nastaveny na různé hodnoty.

Tabulka 2 – Seznam jednotlivých dvojic estimátor-adaptivní regulátor v navrženém multiestimačním schématu

č.	Identifikační algoritmus	Adaptivní regulátor	Popis
1	RLS	LQ regulátor	Rekurzivní metoda nejmenších čtverců
2	RIV1	LQ regulátor	Rekurzivní metoda instrumentální proměnné - varianta 1
3	RIV2	LQ regulátor	Rekurzivní metoda instrumentální proměnné - varianta 2
4	RPLR-OE	LQ regulátor	Rekurzivní metoda pseudolineární regrese pro model OE
5	RPLR-ARMAX	LQ regulátor	Rekurzivní metoda pseudolineární regrese pro model ARMAX
8	RPEM-ARMAX	LQ regulátor	Rekurzivní metoda predikčních chyb pro model ARMAX
7	RPEM-OE	LQ regulátor	Rekurzivní metoda predikčních chyb pro model OE

První sloupec udává index jednotlivých dvojic adaptivní regulátor- identifikační algoritmus. V druhém sloupci je uveden odpovídající rekurzivní identifikační algoritmus a třetí sloupec tabulky charakterizuje použitý adaptivní regulátor v dané dvojici.

9.3 Výsledky simulačního ověřování

Výše uvedené multiestimační schéma bylo simulačně testováno pro různé hodnoty hloubky paměti M , vah α_k, β_k a faktoru zapomínání λ_k .

9.3.1 ME Schéma se sledováním průběhu chyby predikce

Jak bylo uvedeno výše, nadřazený člen může zajišťovat kromě samotného výběru vhodné dvojice adaptivní regulátor – identifikační algoritmus a jejich přepínání další činnosti nezbytné pro zvýšení spolehlivosti STC regulátoru. Jednou z těchto činností je sledování chování identifikačního algoritmu. Sledování této činnosti lze provádět více způsoby (viz. kapitola 8.1.2). Jedním z nich je sledování průběhu chyby predikce na základě vhodně zvoleného kritéria. Při splnění podmínky je algoritmus rekurzivní identifikace vypnut, při jejím nesplnění opět zapnut. Tento způsob odpovídá volbě "Průběh chyby predikce" v položce "Volba kriteria" v nastavení nadřazeného členu (viz. **Tabulka 10**).


V tomto případě je tedy využito sledování průběhu chyby predikce pro zastavení a opětovné spuštění jednotlivých identifikačních algoritmů.

Hodnoty nastavení jednotlivých parametrů nadřazeného členu jsou pro větší přehlednost uvedeny v uvedeny v následující tabulce:

Váhy $[\alpha_k, \beta_k, \lambda_k]$:	[0.4, 0.6, 0.97]
Hloubka paměti M :	10
Start ME schématu od kroku k :	0
Kriterium	Průběh chyby predikce
Prahové hodnoty kriteria	[0.0001 0.001 0.001 0.02 0.02 0.02 0.02]
Startovní regulátor:	1

Z tabulky vyplývá, že ME Schéma pracuje od prvního kroku regulace a jako startovní dvojice je zvolena dvojice číslo 1, tj. LQ-regulátor – rekurzivní metoda nejmenších čtverců.

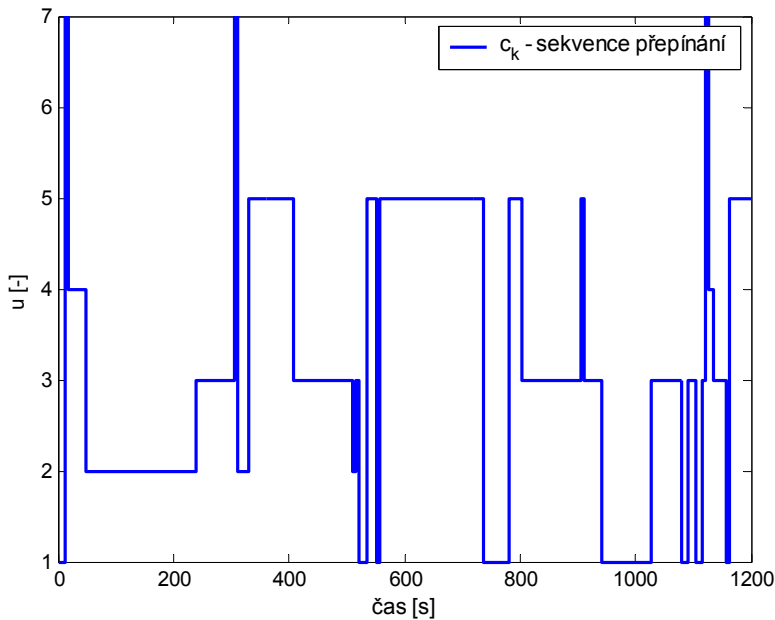
Průběh regulačního pochodu je uveden na Obr. 9.2. Z grafického průběhu regulačního pochodu lze konstatovat, že základní požadavek regulace na trvalou nulovou regulační odchylku byl splněn. Jednotlivé přeskoky v průběhu regulované veličiny v daných časových okamžicích (viz. **Tabulka 1**) jsou způsobeny změnami parametrů řízeného systému a také výraznějšími změnami akční veličiny v daných časových okamžicích.



Obr. 9.2: Adaptivní řízení: Multiestimační schéma

Na Obr. 9.3 je uvedena sekvence přepínání mezi jednotlivými dvojicemi adaptivní regulátor identifikační algoritmus. Osa y udává index jednotlivých dvojic adaptivní regulátor – identifikační algoritmus aktivních v jednotlivých časových okamžicích. Z průběhu sekvence přepínání je patrné, že při dané volbě vah nejsou při adaptivním řízení využity všechny dvojice adaptivní regulátor – identifikační algoritmus.

Problém při použití této komplexnější struktury představuje především volba vhodných vah, která výrazně ovlivňuje hodnotu ukazatele jakosti (8.9). V případě nevhodné volby vah dochází k příliš častému přepínání, což může mít za následek neuspokojivý průběh přechodového děje během regulačního pochodu.



Obr. 9.3: Sekvence přepínání

9.3.2 ME Schéma bez sledování průběhu chyby predikce


Na rozdíl od předchozího případu, není prováděno sledování průběhu chování rekurzivních identifikačních algoritmů. V tomto případě je volba vah provedena tak, že největší důraz je kladen na omezení změn výstupu řízeného systému způsobeného přepínáním mezi jednotlivými regulátory.

Hodnoty nastavení jednotlivých parametrů jsou uvedeny v následující tabulce:

Váhy $[\alpha_k, \beta_k, \lambda_k]$:	[0.1, 0.9, 0.97]
Hloubka paměti M :	10
Start ME schematu od kroku k :	8
Kriterium	Bez kriteria
Startovní regulátor:	3

Z tabulky vyplývá, že ME Schéma není spuštěno od prvního kroku regulace, ale až od kroku $k = 8$ (tj. první 8 kroků regulace pracuje dvojice číslo 3 a teprve poté je


umožněn, na základě kritéria, výběr jiné dvojice). Jako startovní dvojice je zvolena dvojice číslo 3, tj. LQ-regulátor – rekurzivní metoda instrumentální proměnné.



Obr. 9.4: Adaptivní řízení: Multiestimační schéma

Průběh regulačního pochodu je uveden na Obr. 9.4. Z grafického průběhu regulačního pochodu lze konstatovat, že základní požadavek regulace na trvalou nulovou regulační odchylku byl splněn. Jednotlivé překymity v průběhu regulované veličiny v daných časových okamžicích jsou způsobeny změnami parametrů řízeného systému (viz. **Tabulka 1**). Z průběhu akčního zásahu vyplývá, že tato volba vah způsobuje potlačení výrazných změn v jeho průběhu, což má za následek hladší průběh regulované veličiny.

Na Obr. 9.5 je uvedena sekvence přepínání mezi jednotlivými dvojicemi adaptivní regulátor identifikační algoritmus. Osa y udává index jednotlivých dvojic adaptivní regulátor – identifikační algoritmus aktivních v jednotlivých časových okamžicích. Z průběhu sekvence přepínání je patrné, že při dané volbě vah dochází k omezení počtu přepnutí mezi jednotlivými dvojicemi adaptivní regulátor – identifikační algoritmus a také je výběr některých dvojic adaptivní regulátor – identifikační algoritmus zcela potlačen.




Obr. 9.5: Sekvence přepínání

9.3.3 Adaptivní řízení s jednoduchým samočinně se nastavujícím regulátorem

V tomto případě, je pro účely adaptivního řízení využita pouze první dvojice multiestimačního schématu, tj. odhad parametrů modelu řízeného procesu je prováděn pomocí rekurzivní metody nejmenších čtverců (RLS) a syntéza regulátoru (adaptivní LQ-regulátor) je pak prováděna v každém kroku regulace na základě takto získaných odhadů parametrů.

Průběh regulačního pochodu je uveden na Obr. 9.6. Z grafického průběhu regulačního pochodu lze konstatovat, že základní požadavek regulace na trvalou nulovou regulační odchylku byl splněn. Průběh regulované veličiny však na rozdíl od předchozích případů obsahuje výraznější překmity, které jsou způsobeny prudšími změnami akční veličiny.



Obr. 9.6: Adaptivní řízení: Jednoduchý samočinně se nastavující regulátor

9.4 Rozbor výsledků

9.4.1 Porovnání jednotlivých metod

Pro srovnání výsledků jednotlivých metod je třeba použít nějakou metodu určující kvalitu regulace. Pro výpočet kvality regulace bylo vybráno kritérium založené 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 následujících vztahů:

$$S_u = \frac{1}{k_2 - k_1 + 1} \sum_{k=k_1}^{k_2} \Delta u^2(k), \quad S_y = \frac{1}{k_2 - k_1 + 1} \sum_{k=k_1}^{k_2} e^2(k) \quad (9.2)$$

K vyhodnocování kvality regulace můžeme samozřejmě použít i jiných metod, jejichž princip lze najít v jakékoliv literatuře zabývající se statistickými metodami.

9.4.2 Vyhodnocení jednotlivých metod

Tabulka 3 – Kriteria kvality regulace pro simulační ověřování

Metoda	S_u	S_y
ME schéma se sledováním průběhu chyby predikce	0.0032881	0.002293
ME schéma bez sledování průběhu chyby predikce	0.016148	0.001599
Jednoduchý STC	0.046316	0.002805

Z výše uvedené tabulky je patrné, že navržené multiestimační schéma poskytuje z hlediska kvality regulace lepší výsledky než jednoduchý adaptivní regulátor.

Z grafických průběhů je patrné, že základní požadavek regulace na trvalou nulovou regulační odchylku byl splněn ve všech případech.

Hlavní přínos navržené složitější struktury oproti jednoduché struktuře samočinně se nastavujícího regulátoru spočívá ve zlepšení průběhu přechodového děje při prudkých změnách parametrů řízeného systému, což je patrné z grafického vyhodnocení průběhu regulačních pochodů a akčních zásahů (viz. Obr. 9.2, Obr. 9.4 versus Obr. 9.6).

Problém při použití této komplexnější struktury představuje především volba vhodných vah, které výrazně ovlivňují hodnotu ukazatele jakosti (8.9). V případě nevhodné volby vah dochází k příliš častému přepínání, což má za následek neuspokojivý průběh přechodového děje během regulačního pochodu. Volbu vah je nutné provádět na základě zkušeností a znalostí o daném řízeném systému. Příkladem může být extrémní nastavení vah v případě 9.3.2, kdy je největší váha dána na hodnocení změn způsobených jednotlivými regulátory při jejich možném přepnutí, což má za následek hladší průběh akčního zásahu (jsou potlačeny výrazné změny v jeho průběhu) a tím hladšího průběhu regulované veličiny bez výrazných překmitů. Z grafického průběhu sekvence přepínání je patrné, že taková volba také výrazně omezuje počet přepnutí mezi jednotlivými dvojicemi estimátor-adaptivní regulátor (některé jsou zcela potlačeny).

Svou roli také hraje volba prahových hodnot jednotlivých kritérií pro sledování průběhů chování jednotlivých rekurzivních identifikačních metod. Při nesprávné volbě dochází k vypínání a opětovnému zapínání jednotlivých rekurzivních identifikačních

metod v nevhodných okamžicích, což může vést k tomu, že identifikační metody neposkytují spolehlivé odhady parametrů modelu procesu a průběhu regulačního pochodu je neuspokojivý.

Obecně lze ale konstatovat, že tato složitější struktura poskytuje pro časté a náhlé změny parametrů řízeného systému při vhodné volbě volitelných parametrů lepší výsledky než jednodušší struktura samočinně se nastavujícího regulátoru.

10 EXPERIMENTÁLNÍ OVĚŘENÍ NA REÁLNÉM MODELU


10.1 Popis laboratorního modelu

Pro ověření navržené složitější struktury (multiestimačního schématu) v laboratorních podmínkách, byl zvolen model tří nádrží DTS200.



Obr. 10.1: Laboratorní model DTS200 – Tři nádrže

Jedná se o mnohazměrový nelineární systém sestávající ze tří spojených válcových nádrží, dvou čerpadel, šesti ventilů, trubek, senzorů pro měření výšky hladiny. Schéma systému je uvedeno na obrázku (viz. Obr. 10.2). Čerpadlo P1 řídí přítok kapaliny do nádrže T1, čerpadlo P2 řídí přítok do nádrže T2. Průtok kapaliny mezi nádržemi T1 a T3 může být ovlivňován ventilem V1, průtok kapaliny mezi nádržemi T3 a T2 lze ovlivnit ventilem V2 a výtok z nádrže T2 může být ovlivněn ventilem V3. Systém také nabízí možnost simulace průsaku z jednotlivých nádrží pomocí ventilů V4, V5 a V6.



Obr. 10.2: Schéma laboratorního modelu DTS200 – Tři nádrží

10.1.1 Připojení modelu k PC

Připojení reálného modelu – systému tří nádrží je realizováno pomocí technologické karty Advantech PCL 1716. Programy pro řízení reálné soustavy byly vytvořeny v programovém prostředí MATLAB&SIMULINK ve formě blokových schémat a tzv. s-funkcí.

10.2 Popis Real Time Toolbox

Pro řízení modelu bylo využito prostředí MATLAB&SIMULINK za podpory Real Time Toolboxu. Real Time Toolbox umožňuje téměř bez znalosti hardwarové problematiky okamžitý přístup k vnějším analogovým signálům. Je možné používat buď tradiční styl MATLABu - příkazovou řádku, nebo grafické uživatelské rozhraní, nebo knihovnu systému SIMULINK. Je možné experimentovat na vnějších signálech přímo z MATLABu, bez nutnosti přenášet data ze specializovaných programů pro sběr dat, bez nutnosti kompilace nebo jiných složitých a časově náročných činností. To je ideální pro zpracování signálů, návrhy řídicích systémů a podobné úlohy.

Přesný popis parametrů jednotlivých příkazů a další méně významné příkazy lze nalézt v příručce k Real Time Toolboxu [41].


10.3 Výsledky ověřování na laboratorním modelu

Výsledné multiestimační schéma (viz. Obr. A.1) je sestaveno, podobně jako v předchozích případech pro simulační ověření, ze 7 různých rekurzivních identifikačních algoritmů (a jim odpovídajících adaptivních regulátorů) běžících paralelně. Seznam (včetně pořadí) těchto algoritmů je uveden v tabulce (viz. **Tabulka 2**)

Všechny adaptivní regulátory použité v jednotlivých dvojicích estimátor-adaptivní regulátor v uvedeném schématu jsou stejného typu, jedná se o adaptivní LQ regulátor, jehož popis je uveden v kapitole 8.1.3.1.

Poloha ventilů během experimentu byla konstantní. Ventily V1, V2, V3 a V6 byly plně otevřeny a ventily V4 (průsak z nádrže T1) a V5 (průsak z nádrže T3) byly v pozicích odpovídajících přibližně polovině jejich rozsahu.

Statická charakteristika systému je znázorněna Obr. 10.3.



Obr. 10.3: Statická charakteristika laboratorního modelu DTS200

Vstupní a výstupní signály byly zvoleny následujícím způsobem: Regulovaná veličina je výška hladiny v prostřední nádrži T3. Akční zásah je příkon motoru čerpadla P1.

Počáteční hodnoty vektoru odhadu parametrů pro jednotlivé rekurzivní identifikační algoritmy byly nastaveny následujícím způsobem:

$$\text{RLS, RIV1, RIV2, RPLR-OE, RPEM-OE: } \hat{\boldsymbol{\theta}}^T(0) = [0.1, 0.2, 0.3, 0.4]$$

$$\text{RPLR-ARMAX, RPEM-ARMAX: } \hat{\boldsymbol{\theta}}^T(0) = [0.1, 0.2, 0.3, 0.4, 0.5, 0.6]$$

Pro zajištění sledování časově proměnlivých parametrů, jsou do jednotlivých rekurzivních identifikačních algoritmů implementovány tzv. faktory zapomínání. V našem případě se jedná o adaptivní směrové zapomínání. Počáteční hodnoty faktoru zapomínání jsou nastaveny pro všechny uvedené rekurzivní identifikační algoritmy následujícím způsobem: $\varphi(0) = 1$, $\rho(0) = 0.99$, $\nu(0) = 10^{-6}$, $\lambda(0) = 0.001$.

Perioda vzorkování $T_0 = 2s$ a prodleva mezi jednotlivými přepnutími $N_D = 2$ jsou shodné pro všechny provedené experimenty na reálném laboratorním modelu. Hloubka paměti M , váhy α_k, β_k a faktor zapomínání λ_k pro vyhodnocování kritéria (8.9) byly pro jednotlivé provedené experimenty nastaveny různě.

Výše uvedené multiestimační schéma bylo testováno pro různé hodnoty hloubky paměti M , vah α_k, β_k a faktoru zapomínání λ_k .

10.3.1 ME Schema bez sledováním průběhu chyby predikce


Není prováděno sledování průběhu chování rekurzivních identifikačních algoritmů. V tomto případě je volba vah provedena tak, že největší důraz je kladen na omezení změn výstupu řízeného systému způsobeného přepínáním mezi jednotlivými regulátory.

Hodnoty nastavení jednotlivých parametrů jsou uvedeny v následující tabulce:

Váhy $[\alpha_k, \beta_k, \lambda_k]$:	[0.1, 0.9, 0.97]
Hloubka paměti M :	10
Start ME schematu od kroku k :	20
Kriterium	Bez kritéria
Startovní regulátor:	3

Z tabulky vyplývá, že ME Schéma není spuštěno od prvního kroku regulace, ale až od kroku $k=20$ (tj. první 20 kroků regulace pracuje dvojice číslo 3 a teprve poté je umožněn, na základě vyhodnocení kritéria, výběr jiné dvojice). Jako startovní dvojice je zvolena dvojice číslo 3, tj. LQ-regulátor – rekurzivní metoda instrumentální proměnné.

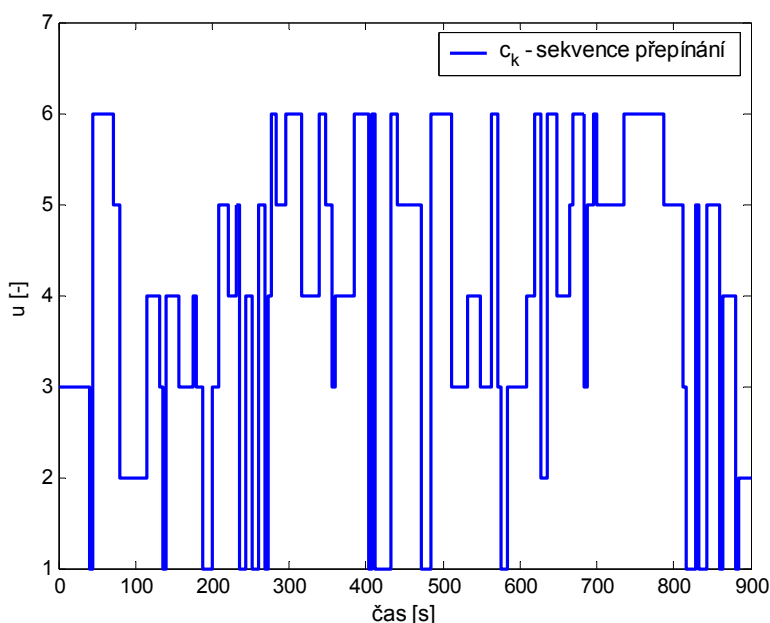
Průběh regulačního pochodu je uveden na Obr. 10.4. Z grafického průběhu regulačního pochodu lze konstatovat, že základní požadavek regulace na trvalou nulovou regulační odchylku byl splněn. Regulovaná veličina dosáhla žádané hodnoty rychleji, než v případě jednoduchého STC regulátoru (viz. Obr. 10.6).



Obr. 10.4: Adaptivní řízení: Multiestimační schéma

Z průběhu akční veličiny vyplývá, že navzdory dané volbě vah (která by měla zabránit prudkým změnám regulované veličiny) nedošlo k potlačení výrazných změn v jejím průběhu, přesto je však průběh regulované veličiny uspokojivý.

Na Obr. 10.5 je uvedena sekvence přepínání mezi jednotlivými dvojicemi adaptivní regulátor identifičací algoritmus. Osa y udává index jednotlivých dvojic adaptivní regulátor – identifičací algoritmus aktivních v jednotlivých časových okamžicích. Z průběhu sekvence přepínání je patrné, že navzdory dané volbě vah, která by měla mít za následek eliminaci počtu přepnutí mezi jednotlivými dvojicemi adaptivní regulátor – identifičací algoritmus dochází k častému přepínání mezi jednotlivými dvojicemi adaptivní regulátor – identifičací algoritmus.

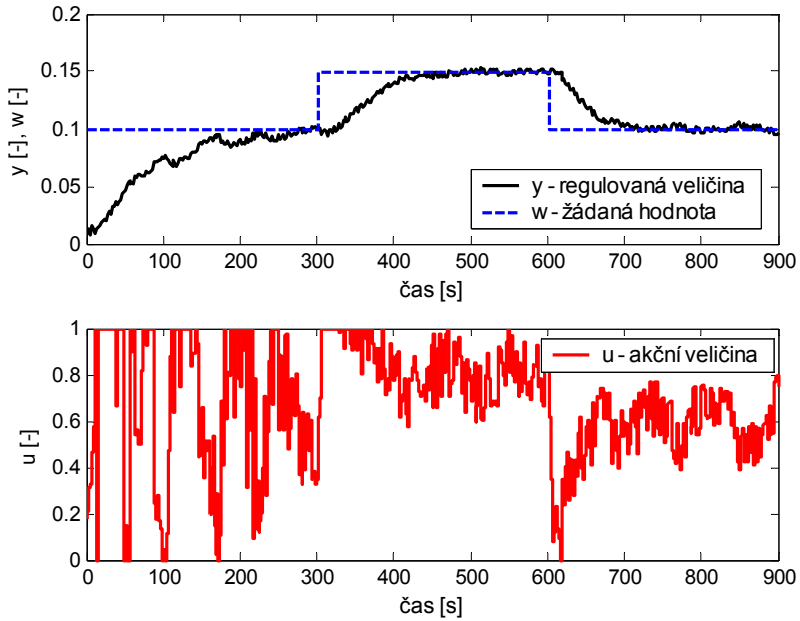


Obr. 10.5: Sekvence přepínání

10.3.2 Adaptivní řízení s jednoduchým samočinně se nastavujícím regulátorem

V tomto případě, je pro účely adaptivního řízení využita pouze první dvojice multiestimačního schématu, tj. odhad parametrů modelu řízeného procesu je proveden pomocí rekurzivní metody nejmenších čtverců (RLS) a syntéza regulátoru je pak prováděna v každém kroku regulace na základě takto získaných odhadů parametrů.

Průběh regulačního pochodu je uveden na Obr. 10.6. Z grafického průběhu regulačního pochodu lze konstatovat, že základní požadavek regulace na trvalou nulovou regulační odchylku byl splněn. Regulovaná veličina dosáhla žádané hodnoty pomaleji, než v případě použití multiestimačního schématu. Průběh akční veličiny obsahuje menší změny než v předchozím případě.



Obr. 10.6: Adaptivní řízení: Jednoduchý samočinně se nastavující regulátor

10.4 Rozbor výsledků

10.4.1 Vyhodnocení jednotlivých metod

Tabulka 4 – Kriteria kvality regulace pro simulační ověřování

Metoda	S_u	S_y
ME schema bez sledování průběhu chyby predikce	0.110663	0.000548
Jednoduchý STC	0.039119	0.000716

Z výše uvedené tabulky je patrné, že navržené multiestimační schema poskytuje z hlediska průběhu regulované veličiny lepší výsledky než jednoduchý adaptivní regulátor.

Z grafických průběhů je patrné, že základní požadavek regulace na trvalou nulovou regulační odchylku byl splněn ve všech případech.

Hlavní přínos navržené složitější struktury oproti jednoduché struktuře samočinně se nastavujícího regulátoru spočívá ve zlepšení průběhu přechodového děje při změnách parametrů řízeného systému, což je patrné z grafického vyhodnocení průběhu regulačních pochodů (viz Obr. 10.4 a Obr. 10.6).

Problém při použití této komplexnější struktury představuje především volba vhodných vah, které výrazně ovlivňují hodnotu ukazatele jakosti (8.9). V případě nevhodné volby vah dochází k příliš častému přepínání, což má za následek neuspokojivý průběh přechodového děje během regulačního pochodu. Volbu vah je nutné provádět na základě zkušeností a znalostí o daném řízeném systému. Příkladem může být extrémní nastavení vah v případě, kdy je největší váha dána na hodnocení změn způsobených jednotlivými regulátory při jejich možném přepnutí, což by mělo mít za následek hladší průběh akčního zásahu (měly by být potlačeny výrazné změny v jeho průběhu) a tím hladšího průběhu regulované veličiny bez výrazných překmitů. Z grafického průběhu je však patrné, že tato volba, navzdory tomu, že nezpůsobila zmírnění změn akčního zásahu měla za následek hladší průběh regulované veličiny.

Svou roli také hraje volba prahových hodnot jednotlivých kritérií pro sledování průběhů chování jednotlivých rekurzivních identifikačních metod. Při nesprávné volbě dochází k vypínání a opětovnému zapínání jednotlivých rekurzivních identifikačních

metod v nevhodných okamžicích, což může vést k tomu, že identifikační metody neposkytují spolehlivé odhady parametrů modelu procesu a průběhu regulačního pochodu je neuspokojivý.

Obecně lze ale konstatovat, že tato složitější struktura poskytuje pro časté a náhlé změny parametrů řízeného systému při vhodné volbě volitelných parametrů lepší výsledky než jednodušší struktura samočinně se nastavujícího regulátoru.

11 ZÁVĚR

Je zřejmé, že při návrhu adaptivního řízení je úloha identifikace stejně důležitá jako role syntézy regulátoru. Nejčastěji se pro identifikaci používá regresní (ARX) model, jehož parametry se průběžně odhadují metodou nejmenších čtverců. Je to jednoduchá a velmi dobře použitelná metoda. V určitých situacích, kdy je měřená veličina výrazně zatížená šumem, jehož vlastnosti nelze charakterizovat odhadovanými parametry matematického modelu, vede metoda nejmenších čtverců k nespolehlivým odhadům parametrů a následně k návrhu regulátoru, který nemusí spolehlivě pracovat. Tyto problémy lze odstranit několika způsoby. Jedním z nich je použitím jiných, složitějších typů modelů (ARMAX a OE), které jsou uvedeny v této práci a jim odpovídající vyšší formy rekurzivních identifikačních algoritmů pro odhad parametrů těchto vybraných modelů. Tyto pak poskytují kvalitnější odhady parametrů modelu procesu, což je předpoklad pro zlepšení spolehlivosti algoritmů v adaptivních systémech řízení.

V této práci byla popsána další možnost zlepšení spolehlivosti a výkonu samočinně se nastavujícího regulátoru, která využívá výše uvedeného předpokladu. Postup spočívá v nahrazení jednoduchého rekurzivního identifikačního schématu složitější strukturou, která je založena na paralelním běhu vybraných rekurzivních identifikačních algoritmů pro odhad parametrů složitějších modelů. Ke každému identifikačnímu algoritmu je pak přiřazen odpovídající adaptivní regulátor. Nadřazený člen pak na základě vhodného kritéria vybírá v reálném čase nejvhodnější dvojici estimátor-regulátor. Základní užitečnost této struktury spočívá ve zvýšení přesnosti odhadů parametrů, což má za následek hladší průběh akčního zásahu a tím zlepšení přechodového děje v průběhu regulačního pochodu.

Pro simulační a experimentální ověřování navrženého řešení na reálném laboratorním modelu, byl vytvořen program v programovém prostředí MATLAB&SIMULINK 6.5. Program je realizován jako blokové schéma v prostředí SIMULINK. Umožňuje provést volbu nezbytných počátečních podmínek pro jednotlivé identifikační algoritmy a jim odpovídající regulátory a dále provést nastavení vstupních parametrů nadřazeného členu.

Na základě simulačního i praktického ověření na reálném laboratorním modelu lze konstatovat, že navržené řešení umožnilo zlepšení spolehlivosti a výkonu samočinně se nastavujícího regulátoru.

Hlavní přínos práce spočívá v návrhu způsobu zlepšení spolehlivosti a výkonu samočinně se nastavujícího regulátoru. Na základě využití známých stávajících rekurzivních identifikačních metod je vytvořeno tzv. multiestimační schéma, které umožňuje zlepšení přechodového děje v průběhu regulačního pochodu. Navržené multiestimační schéma je realizováno v programovém prostředí MATLAB&SIMULINK jako blokové schéma nadstavby SIMULINK, což umožňuje jeho snadné využití pro účely simulace i pro uskutečňování experimentů na reálných objektech.

LITERATURA

- [1] Åström, K. J. Maximum Likelihood and Prediction Error Methods. *Automatica*, 1980, Vol. 16, No. 5, pp. 551-574.
- [2] Balátě, J. *Vybrané statě z automatického řízení*. 2. vyd. Brno : Vysoké učení technické v Brně, 1996. 360 s. ISBN 80-214-0793-X.
- [3] Balátě, J. *Automatické řízení*. 1. vyd. Praha : BEN-technická literatura, 2003. 664 s. ISBN 80-7300-020-2.
- [4] Bittanti, S., Bolzern, P., Campi, M. (1990). Exponential convergence of modified directional forgetting identification algorithm. *System & Control Letters*, 14, 131-137.
- [5] Bobál, V. *Identifikace systémů*. Zlín: Ediční středisko VUT Brno, 1990.
- [6] Bobál, V. *Teorie automatického řízení III*. Zlín: Ediční středisko VUT Brno, 1991.
- [7] Bobál, V., Bohm, J. , Prokop, R., Fessl, J. *Praktické aspekty samočinně se nastavujících regulátorů: algoritmy a implementace*. Brno: Nakladatelství VUTIUM, Vysoké učení technické v Brně, 1999. ISBN 80-214-1299-2
- [8] Bobál, V., J. Böhm, J. Fessl and J. Macháček. *Digital Self-tuning Controllers: Algorithms, Implementation and Applications*. London: Springer-Verlag, 2005. ISBN 1-85233-980-2.
- [9] Branica, I., Peric, N., Petrovic, I. Comparison of Several Recursive Identification Methods. *Automatika* 1996, vol.37, no. 3-4, pp. 99-104.
- [10] Corriou, Jean-Pierre. *Process Control : Theory and Applications*. 1st edition. London : Springer, 2004. 750 s. ISBN 1852337761.
- [11] Cunha, J.B., Moura Oliveira P.B., J.P. Coelho, J.P. Recursive parameter estimation algorithms. In *CONTROLO 2004: 6th Portuguese Conference On Automatic Control*, Faro, Portugal, 2004, pp. 109-114.
- [12] De la Sen, M., Alonso-Quesada, S. Robust adaptive control with multiple estimation models for stabilization of a class of non-inversely stable time-varying plants. *Asian Journal of Control* 2003, vol. 6, no. 1, pp. 59-73.

- [13] Elektronické dokumenty Karlstad University. Department of Electrical Engineering, 2003. Dostupné na URL: http://www.ee.kau.se/kurser/tel305/cnotes_6.pdf
- [14] Feldbaum A. A. Dual control theory. *Automation and Remote Control* 1960, vol. 21, no. 9, pp. 874-1039.
- [15] Fikar, M., Mikleš, J. *Identifikácia systémov*, Bratislava: STU v Bratislavě, 1999. ISBN 80-227-1177-2.
- [16] Filatov M.M., Unbehauen H. *Adaptive Dual Control. Theory and Application*. Berlin Heidelberg New York: Springer-Verlag, 2004.
- [17] Fortescue, T.R., Kershenbaum, L.S., Ydstie B.E. Implementation of self-tuning regulators with variable forgetting factor. *Automatica* 1981, vol.17, pp. 831-6.
- [18] Friedlander, B. The Overdetermined Recursive Instrumental Variable Method, *IEEE Trans. on Automatic Control* 1984, vol. AC-29, no.4, pp.353-356.
- [19] Gertler, J. and Banyasz, C. A Recursive (On-Line) Maximum Likelihood Identification Method. *IEEE Trans. on Automatic Control* 1974, vol. AC-19, no. 6, pp. 816-820.
- [20] Gunnarson, S. *Combining Tracking and Regularization in Recursive Least Square Identification*. Department of Electrical Engineering, Linköping University. Dostupné na URL: <http://citeseer.ist.psu.edu/41116.html>.
- [21] Hill, H.J., Ydstie, B.E. Adaptive control with selective memory. *International journal of adaptive control and signal processing*, September 2004, vol.18, no. 7, pp. 571-587.
- [22] Chalupa, P. *Discrete Decentralized Control Systems*, PhD Thesis. Tomas Bata University in Zlin, 2003.
- [23] Ibeas, A., de la Sen, M., Alonso-Quesada, S. A supervised multiestimation scheme for discrete adaptive control. *Proceedings of the Seventh International Conference on Control, Automation, Robotics and Vision*, Singapore, December 2002, pp.659-664.

- [24] Isermann, R., Baur, U., Bamberger, W., Kneppo, P., Siebert, H. Comparison of six on - line identification and parameter estimation methods. *Automatica*, 1974, vol 10, no 1, pp. 81 - 103 .
- [25] Isermann, R., Lachmann, K.-H., Matko, D. *Adaptive Control Systems*. [s.l.] : Prentice Hall, 1992. 541 s. ISBN 0-13-137456-7.
- [26] Jiang J., Zhang Y. A novel variable-length sliding window blockwise least-squares algorithm for on-line estimation of time-varying parameters. *International Journal of Adaptive Control and Signal Processing*, August 2004, Vol.18, No. 6, pp. 505-521.
- [27] Kulhavý, R. (1985). Restricted exponential forgetting in real-time identification. *Proceedings of IFAC*, 1985, pp. 1143–1148.
- [28] Kulhavý, R., Kárný, M. Tracking of slowly varying parameters by directional forgetting. *In Proc. 9th IFAC World Congr.*, Budapest 1984, pp. 79-83.
- [29] Kulhavý, R., Zarrop M.B. On a general concept of forgetting. *International Journal of Control* 1993, vol. 58, no.4, pp. 905–924.
- [30] Ljung L, Gunnarsson S. Adaptation tracking in system identification - A survey. *Automatica* 1990; vol. 26, pp. 7-22.
- [31] Ljung, L. *System Identification: Theory for User*. N.J. USA: Prentice-Hall, Englewood Cliffs, 1987. 520 p. ISBN 0-13-881640-9.
- [32] Ljung, L. *MATLAB System Identification Toolbox User's Guide*, Version 5. The Mathworks, 2000.
- [33] Ljung, L., Söderström, T. *Theory and practice of recursive identification*. MIT Press, Cambridge, Mass., 1983.
- [34] Moore, J. B. and Weiss, H. Recursive Prediction Error Methods for Adaptive Estimation. *IEEE Trans. on Systems, Man, and Cybernetics* 1979, vol. SMC-9, no. 4, pp. 197-205.
- [35] Moore, J. B., Boel, R. K. Asymptotically Optimum Recursive Prediction Error Methods in Adaptive Estimation and Control. *Automatica* 1986, vol. 22, no. 2, pp. 237-240.

- [36] Narendra, K. S., Balakrishnan, J. Adaptive control using multiple models. *IEEE Transactions on Automatic Control* 1997, vol. 42, no. 2, pp. 171-187.
- [37] Narendra; K. S., Balakrishnan, J., Ciliz, M. K. Adaptation and learning using multiple models, switching, and tuning. *IEEE Control Systems Magazine* 1995, vol. 15, no. 3, pp. 37-51
- [38] Nelles, O. *Nonlinear system identification*. Germany, Berlin: Springer-Verlag 2001. 785 p. ISBN 3-540-67369-5.
- [39] Noskievič, P. Modelování a identifikace systémů. Ostrava: MONTANEX a.s., 1999. 276 s. ISBN 80-7225-030-2
- [40] Poulin, E., Pomerleau, A., Desbiens, A., Hodouin, D. Development and Evaluation of an Auto-tuning and Adaptive PID controller. *Automatica* 1995, Vol. 32.
- [41] REAL TIME TOOLBOX for use with MATLAB User's manual. Praha: HUMUSOFT s.r.o., 1992 – 1998.
- [42] Rohaľ-Ilkiv B. *Identifikácia sústav*. 1.vyd. Bratislava: Edičné stredisko Slovenské vysoké školy technické, 1987. 206s.
- [43] Salgado M. E., Goodwin G. C. and Middleton R. H.. Exponential Forgetting and Resetting, *International Journal of Control*, 1988, Vol. 47, No. 2, p. 477.
- [44] Saridis, G., N. Comparison of six on-line identification algorithms. *Automatica* 1974, vol. 10, no. 1, pp. 69-79.
- [45] Söderström, T., Stoica, P. *System Identification*. Cambridge, Prentice Hall, University Press 1989. 612 p. ISBN 0-13-127606-9.
- [46] Vahidi, A., Stefanopoulou, A., Peng H. Recursive Least Square with Forgetting for Online Estimation of Vehicle Mass and Road Grade. *Journal of Vehicle System Dynamics* 2005, vol. 43, pp. 31-57.
- [47] Wellstead, P.E., Zarrop, M.B. *Self-Tuning System – Control and Signal Processing*, John Wiley & Sons Ltd. 1991. 580 p. ISBN 0-471-93054-7.
- [48] Wilson, D.I. *Identification of control-type models*. Karlstad University (Educational Textbooks), 2001.

- [49] Zhou, Q., Cluett, W., R. Recursive Identification of Time-varying Systems via Incremental Estimation. *Automatica* 1996, vol 32, no. 10, pp. 1427-1431.

PUBLIKAČNÍ AKTIVITY

Konferenční příspěvky

1. Sysel, M., Navrátil, P.: Delta modification of self-tuning controllers. Student Forum ECC 2001, 2001, p. 1-4.
2. Navrátil, P., Dostál, P., Bobál, V.: Adaptive control of TITO system using delta model. In: Proc. 5th Portuguese Conference on Automatic Control, Aveiro, Portugal, 2002, 114-119 (ISBN 972-789-072-5).
3. Navrátil, P., Bobál, V., Sysel, M.: Mnoharozměrové adaptivní řízení s využitím delta modelů. In: Proc. 5th International Scientific-Technical Conference Process Control 2002, Kouty n. Desnou, Czech Republic, 2002, Paper No. R119 (ISBN 80-7149-452-1).
4. Navrátil, P., Bobál, V.: Mnoharozměrové adaptivní řízení využitím delta modelů v programovém prostředí MATLAB. In: Konference MATLAB 2002, Kongresové centrum ČVUT Praha, 2002, 368-377.
5. Bobál, V., Navrátil, P., Dostál, P.: Adaptive control of a two input – two output system using delta models. In: 10th IEEE Mediterranean Conference on Control and Automation MED 2002, Lisboa, Portugal, July 9-12, 2002, Paper No. TUP4-5.
6. Perůtka, K., Navrátil, P., Adámek, M., Bobál, V.: Comparison of decentralized and multidimensional adaptive control using delta models. In: Proc. of the 13th International DAAAM Symposium “Intelligent Manufacturing & Automation: Learning from Nature”, Vienna University of Technology, Vienna, Austria, 2002, 421-422.
7. Perůtka, K., Bobál, V., Navrátil, P. Decentralized adaptive control: Influence of identification algorithm on control. In: Proc. of 3rd International Carpathian Control Conference ICC‘2002, Malenovice, pp. 241-246
8. Novák, J., Navrátil, P., Navrátil, M.: The selection of the suitable type of the forgetting factor for performance improvement of the adaptive controller. In: Proc.

- 14th International Conference Process Control 2003, Štrbské Pleso, High Tatras, Slovak Republic, June 8-11, 2003, Paper No. PC168 (ISBN 80-227-1902-1).
9. Bobál, V., Navrátil, P., Dostál, P., Sysel, M.: Self-tuning control of MIMO systems: comparison 1DOF and 2DOF configurations. In: Proc. of the IASTED International Conference of Circuits, Signals and Systems, Cancun, Mexico, 2003, 5 - 10.
 10. Navrátil, P., Bobál, V.: Recursive Identification Methods for Self-Tuning Controller. In Proc. 15th International Conference Process Control 2005, Štrbské Pleso, Slovakia, June 7-10, 2005, Paper No. 046f (ISBN 80-227-2235-9).
 11. Navrátil, P., Bobál, V.: Recursive Parameter Estimation Algorithms. In Proc. of the 16th INTERNATIONAL DAAAM SYMPOSIUM "Intelligent Manufacturing & Automation: Focus on Young Researchers and Scientists", University of RIJEKA, OPATIJA, CROATIA, October 19-22, 2005, 269-270. (ISBN 3-901509-46-1)
 12. Navrátil, P., Bobál, V.: Adaptivní řízení systému tří nádrží v prostředí MATLAB & Simulink. In *Technical Computing Prague 2005*. Kongresové centrum ČVUT Praha, November 15, 2005. (ISBN 80-7080-577-3).
 13. Navrátil, P., Bobál, V.: Multiestimation Scheme for Self-Tuning Controller. In Proc. 7th International Scientific – Technical Conference PROCESS CONTROL 2006, Kouty nad Desnou, June 13-16, 2006, Paper No. R034a (ISBN 80-7194-860-8)
 14. Navrátil, P., Bobál, V.: Recursive Identification Algorithms Library. In Proc. 7th International Scientific – Technical Conference PROCESS CONTROL 2006, Kouty nad Desnou, June 13-16, 2006, Paper No. R034b (ISBN 80-7194-860-8)
 15. Navrátil, P., Bobál, V., Dostál, P. Self-Tuning Control of Three Tank System. In Proc. The 6th ASIAN CONTROL CONFERENCE ASCC 2006, Bali, Indonesia, July 18-21, 2006, 1160-1165. (ISBN 979-15017-0)

Příspěvky v domácích a zahraničních časopisech

1. Bobál, V., Navrátil, P., Kubalčík, M.: Delta modifikace adaptivního řízení laboratorního modelu CE 108. *AT&P Journal plus* 4, 10, 2003, 45-51.

Mimo výše popsaných konferenčních příspěvků jsem uveden jako vedoucí těchto bakalářských a diplomových závěrečných prací:

- 1 Navrátil, J. Numerické metody pro identifikaci přechodových charakteristik, bakalářská závěrečná práce, UTB ve Zlíně, FT, IIT, 2004.
- 2 Šálek, J. Elektronický manuál pro System Identification Toolbox, bakalářská závěrečná práce, UTB ve Zlíně, FT, IIT, 2005.
- 3 Vaculíková, M. Elektronický manuál pro program SCILAB, bakalářská závěrečná práce, UTB ve Zlíně, FAI, 2005.
- 4 Macků, R. Laboratorní tloušťkoměr, diplomová závěrečná práce, UTB ve Zlíně, FAI, 2006.
- 5 Olbert, V. Realizace rekurzivních metod identifikace v prostředí MATLAB&SIMULINK, diplomová závěrečná práce, UTB ve Zlíně, FAI, 2006.

ODBORNÝ ŽIVOTOPIS AUTORA – CURRICULUM VITAE

Jméno: Ing. Petr Navrátil

Datum narození: 16.9.1977, Uherské Hradiště

Vzdělání: 1992-1996 SPŠ Uherské Hradiště, obor strojírenství
1996-2001 VUT v Brně, Fakulta technologická ve Zlíně (od 1.1.2001 Univerzita Tomáše Bati ve Zlíně), obor „Automatizace a řídicí technika ve spotřebním průmyslu“
2001-2007 UTB ve Zlíně, Fakulta technologická, obor Technická kybernetika, doktorské studium

Praxe: od 2004 asistent na UTB ve Zlíně, Fakulta aplikované informatiky, ústav řízení procesů (do 31.12.2005 UTB ve Zlíně, Fakulta technologická, Institut řízení procesů a aplikované informatiky)


PŘÍLOHA A

A.1. Stručný popis vytvořeného programového vybavení

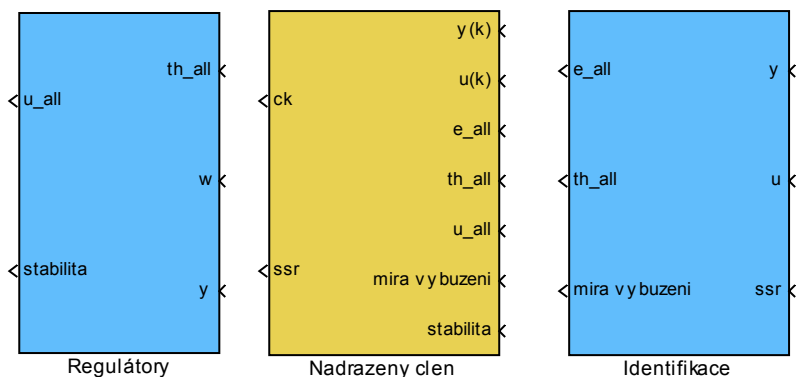
Program byl vytvořen v programovém prostředí MATLAB a využívá nadstavbu SIMULINK pro simulační a reálné ověřování navrženého postupu.

Výsledné zapojení vytvořené v prostředí SIMULINKu sestává z několika dílčích částí tzv. subsystémů, jedná se především o tyto bloky *Nadřazený člen*, *Regulátor*, *Identifikace*. Tyto subsystémy jsou tvořeny dalšími jednoduššími bloky. Jednotlivé subsystémy obsahují tzv. masku, která umožňuje definování dialogu pro zadávání jednotlivých volitelných parametrů dílčích subsystémů.

Celkového zapojení jednotlivých subsystémů, které tvoří dílčí části celého výsledného systému, je uvedeno na následujícím obrázku (viz. Obr. A.1). Pro větší přehlednost jsou jednotlivé subsystému barevně zvýrazněny.



Obr. A.1: Celkové zapojení ME schématu



Obr. A.2: Obrázky jednotlivých subsystémů

Popis vstupů a výstupů jednotlivých bloků

Tabulka 5 – Popis vstupů a výstupů bloku Regulátory

Vstupy	Popis
th_all	- vektor odhadu parametrů jednotlivých estimátorů
w	- žádaná hodnota
y	- výstup řízeného systému

Výstupy	Popis
u_all	- vektor akčních zásahů jednotlivých regulátorů
stabilita	- vektor - stabilita uzavřeného obvodu s jednotlivými regulátory

Tabulka 6 – Popis vstupů a výstupů bloku Nadrazeny člen

Výstupy	Popis
ck	- hodnota aktivní dvojice estimátor-adaptivní regulátor
ssr	- vektor s hodnotami pro start/stop/restart jednotlivých estimátorů

Vstupy	Popis
$y(k)$	- výstup řízeného systému
$u(k)$	- akční zásah aktivního regulátoru
e_all	- vektor – chyba predikce od jednotlivých estimátorů
th_all	- vektor odhadu parametrů jednotlivých estimátorů
u_all	- vektor jednotlivých akčních zásahů od regulátorů
mira vybuzení	- vektor míry vybuzení pro jednotlivé estimátory
stabilita	- vektor - stabilita uzavřeného obvodu s jednotlivými regulátory

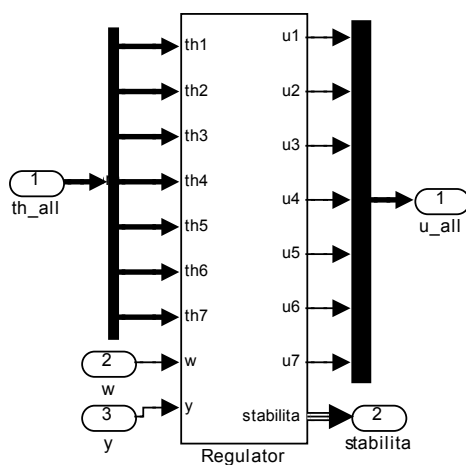
Tabulka 7 – Popis vstupů a výstupů bloku Identifikace

Vstupy	Popis
y	- výstup řízeného systému
u	- akční zásah aktuálního regulátoru
ssr	- vektor s hodnotami pro start/stop/restart jednotlivých estimátorů

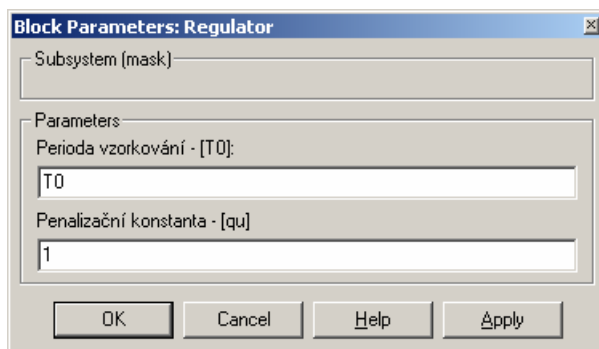
Výstupy	Popis
e_all	- vektor – chyba predikce od jednotlivých estimátorů
th_all	- vektor odhadu parametrů jednotlivých estimátorů
mira vybuzení	- vektor míry vybuzení pro jednotlivé estimátory

Každý z těchto tří základních subsystémů má přiřazen dialog pro zadávání volitelných parametrů. V další části bude popsán význam jednotlivých položek těchto dialogů a uvedena dílčí vnitřní struktura těchto subsystémů.

Subsystém Regulátory



Obr. A.3: Vnitřní struktura bloku Regulátory




Obr. A.4: Dialog pro zadávání parametrů bloku Regulator

Tabulka 8 – Parametry zadávané v dialogu bloku Regulátory

Parametr	Popis
Perioda vzorkování – [T0]:	- volba periody vzorkování
Penalizační konstanta – [qu]:	- volba penalizační konstanty regulátoru


Výsledný subsystém je složen z dílčích regulátorů (všechny jsou stejného typu). Vstupem do jednotlivých regulátorů je vektor parametrů, hodnota regulované veličiny,

žádaná hodnota. Výstupem jednotlivých regulátorů jsou jejich výstupy – akční zásahy a také stabilita uzavřeného regulačního obvodu.

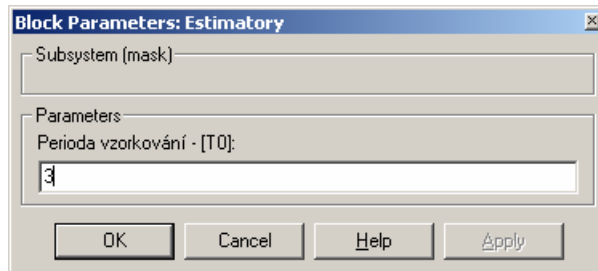


Obr. A.5: Vnitřní struktura bloku Regulator

Subsystém Identifikace



Obr. A.6: Vnitřní struktura bloku identifikace




Obr. A.7: Dialog pro zadávání parametrů bloku Estimatory

Tabulka 9 – Parametry zadávané v dialogu bloku Estimatory

Parametr	Popis
Perioda vzorkování – [T0]:	- volba periody vzorkování

Výsledný subsystém je složen z dílčích estimátorů (tyto estimátory jsou součástí knihovny rekurzivních identifikačních algoritmů - RIA, která byla v rámci dílčí části této práce vytvořena). Vstupem do jednotlivých estimátorů je regulovaná veličina, akční zásah,

vstup pro start/stop/restart algoritmu. Výstupem jednotlivých estimátorů je vektor odhadu parametrů.



Obr. A.8: Vnitřní struktura bloku Estimatory

Subsystém Nadrazený člen

Block Parameters: Nadrazený člen

Nadřazený člen (mask)
pro přepínání mezi jednotlivými dvojicemi estimátor-regulátor na základě vyhodnocení daného kritéria.

Parameters

Koeficienty - [alfa,beta,lambda]:
[0.1,0.9,0.97]

Prodleva mezi přepnutími - [Tau_D]:
2

Počet dvojic estimátor-regulátor - [Ne]:
7

Hloubka paměti - [M]:
10

Start ME schématu od kroku - [k]:
0

Perioda vzorkování - [T0]:
T0

Start posuzování kritérií pro ID od kroku - [k]:
10

Volba kritéria: Průběh chyby predikce

Prahové hodnoty pro míru vybuzení - [1:Nest]:
[0.5 0.5 0.5 0.5 0.5 0.5 0.5]

Prahové hodnoty pro průběh parametrů - [1:Nest]:
[0.001 0.0001 0.0001 0.0001 0.0001 0.0001 0.0005 0.0001]

Prahové hodnoty pro průběh chyby predikce - [1:Nest]:
[0.0001 0.001 0.001 0.02 0.02 0.02 0.02]

Uvažovat stabilitu:

Startovní regulátor: [ID <1 až Nest+1>]
1

OK Cancel Help Apply


Obr. A.9: Dialog pro zadávání parametrů bloku Nadrazený člen

Nadřazený člen je nejdůležitější částí celého systému, neboť provádí na základě daných vstupních dat vyhodnocování ukazatele jakosti a na základě jeho hodnoty výběr aktivní dvojice estimátor-adaptivní regulátor. Vstupními daty jsou regulovaná veličina, akční zásahy jednotlivých regulátorů. Dále pro sledování chování identifikačních algoritmů jsou to průběhy chyb predikce jednotlivých identifikačních algoritmů, průběh parametrů, míra vybuzení a také stabilita dílčích uzavřených regulačních obvodů tvořených

jednotlivými dvojicemi estimátor-adaptivní regulátor a řízeným systémem. Výkonná část tohoto bloku je tvořena tzv. S-funkcí, která obsahuje realizaci výše uvedené procedury.

Tabulka 10 – Parametry zadávané v dialogu bloku Nadražený člen

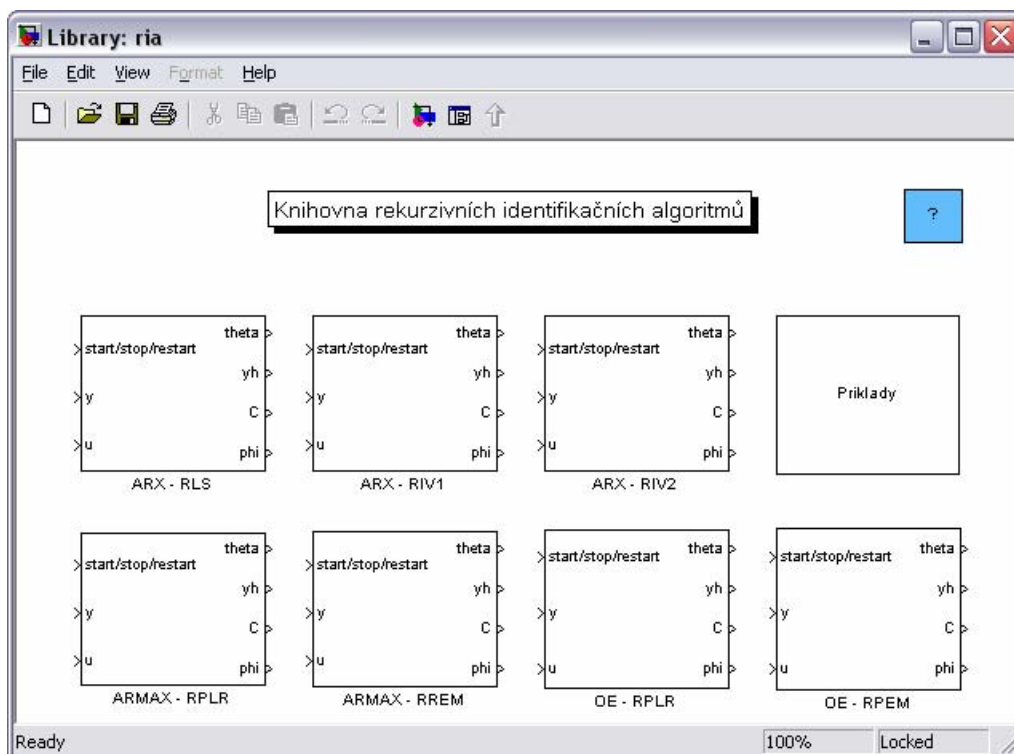
Parametr	Popis
Koeficienty – [alfa, beta, lambda]:	- hodnoty jednotlivých vah pro dané kritérium
Prodleva mezi přepnutími – [Tau_D]:	- prodleva mezi přepnutími jednotlivých možných regulátorů
Počet dvojic estimátor-regulátor – [Ne]:	- počet dvojic estimátorů-regulátorů
Hloubka paměti – [M]:	- hloubka paměti pro vyhodnocení kritérií
Start ME schematu od kroku – [k]:	- volba kroku, od kterého startuje ME schema
Perioda vzorkování – [T0]:	- volba periody vzorkování
Start posuzování kritérií pro ID od kroku – [k]:	- od kterého kroku budou posuzována kritéria uvedená ve volbě "Volba kritéria"
Volba kritéria:	- volba kritéria pro sledování chování jednotlivých identifikačních algoritmů
Prahové hodnoty pro míru vybuzení – [1:Nest]:	- vektor prahových hodnot pro kritérium "míra vybuzení"
Prahové hodnoty pro průběh parametru – [1:Nest]:	- vektor prahových hodnot pro kritérium "Průběh chyby predikce"
Uvažovat stabilitu:	- volba umožňuje zapnutí/vypnutí posuzování stability
Startovní regulátor – [ID <1 až Nest+1>]:	- volba startovního regulátoru



Obr. A.10: Vnitřní struktura bloku Nadržený člen


A.2. Stručný popis knihovny rekurzivních identifikačních algoritmů - RIA

Knihovna rekurzivních identifikačních algoritmů (uvedených v kapitole 6.2) slouží pro odhad parametrů tří základních lineárních dynamických modelů ARX, ARMAX OE a je realizována v prostředí MATLAB&SIMULINK. Sestává ze 7 uživatelských bloků, jejichž jádrem je tzv. S-funkce, která realizuje vybraný rekurzivní identifikační algoritmus.



Obr. A.11: Knihovna rekurzivních identifikačních algoritmů

Každý uživatelský blok realizující daný rekurzivní identifikační algoritmus, obsahuje 3 vstupy a 4 výstupy, jejichž význam je uveden v následující tabulce (viz. **Tabulka 11**). Vstupy jsou tedy vstupně/výstupní data daného objektu a vstup umožňující start/stop/restart daného algoritmu ve zvoleném okamžiku (např. dle vyhodnocení informačního obsahu dat). Výstupy bloku jsou: vektor odhadu parametrů, jedнокroková predikce výstupu modelu, kovarianční matice (možnost např. sledování stopy matice) a vektor dat.



Obr. A.12: Blok knihovny RIA

Tabulka 11 – Popis vstupů a výstupů bloku knihovny

Vstupy	Popis
start/stop/restart	- umožňuje spouštět, zastavovat a restartovat algoritmus 1 - start, 0 – stop, 2 - restart
y	- výstup z identifikovaného systému
u	- vstup do identifikovaného systému

Výstupy	Popis
theta	- vektor odhadu parametrů vybraného modelu
yh	- jednokroková predikce výstupu modelu
C	- kovariační matice
phi	- vektor dat

Poznámka:

Každý blok knihovny obsahuje dialog pro zadávání vstupních parametrů zvoleného bloku. Popis jednotlivých položek dialogů lze nalézt v nápovědě ke knihovně.