

ADAPTIVE CONTROLLERS WITH PRINCIPLES OF ARTIFICIAL INTELLIGENCE AND ITS COMPARISON WITH CLASSICAL IDENTIFICATIONS METHODS

Jakub Dokoupil

Master Degree Programme (2), FEEC BUT
E-mail: xdokou05@stud.feec.vutbr.cz

Supervised by: Petr Pivoňka
E-mail: pivonka@feec.vutbr.cz

ABSTRACT

Presented article is focused on on-line parametric identification methods based on least-squares algorithms and neural networks. The strategy for preventing the problem known as estimator windup which is typical of exponential forgetting algorithm is solved here as well as the observance of positive definition of information matrix. Some ways how to improve accuracy of both methods are also proposed. These properties make them suitable for adaptive control, but a little supremacy is still on the side of methods based on least-squares algorithms.

1. ÚVOD

V případě adaptivního řízení se kvalita regulace odvíjí od dosaženého souladu chování systému s jeho modelem, neboť předpokládáme, že regulátor navržený na kvalitní model bude dostatečně dobře pracovat i na reálném procesu. V práci je proto řešena zejména problematika průběžné parametrické identifikace v uzavřené smyčce. Úlohou regulátoru je v tomto případě stabilizovat proces a kompenzovat poruchy, tato skutečnost spolu s působením šumu a nepřesností měření, v důsledku kvantifikace měřené veličiny A/D převodníky, podstatně zhoršuje možnost identifikace. Cílem je uvedení a rozšíření stávajícího aparátu identifikačních algoritmů pro dosažení potřebné numerické spolehlivosti a stability. Pro V/V identifikaci jsou využívány přístupy klasických metod založených na rekurzivním odhadu parametrů metodami nejmenších čtverců a neuronových estimátorů. Obě dvě třídy metod byly ověřovány v prostředí MATLAB/Simulink prostřednictvím rozhraní GUI (Graphical User Interface) s cílem jejich pozdější přímé implementace do automatů B&R.

2. PROSTŘEDKY ADAPTIVNÍHO ŘÍZENÍ

Jedním z hlavních problémů je identifikace časově proměnných parametrů procesu. V případě metod nejmenších čtverců je nutné algoritmus rozšířit o techniku umožňující potlačování staré informace, neboť nová data $\{\varphi(k)\}$ vystihují proces lépe, než ta stará. Neznámější je konstantní exponenciální zapomínání λ_e [1], kdy exponenciálně klesá vliv dat na odhady parametrů $\hat{\theta}(k)$ a jejich kovarianční matici $P^{-1}(k)$.

$$P^{-1}(k+1) = \lambda_e P^{-1}(k) + \varphi(k+1)\varphi^T(k+1) \quad (1)$$

$$\hat{\theta}(k+1) = \hat{\theta}(k) + P(k+1)\varphi(k+1)[y(k+1) - \varphi^T(k+1)\hat{\theta}(k)] \quad (2)$$

V případě numericky špatně podmíněných situacích, kdy data v sobě obsahují nedostatečné množství informací o dynamice systému, vyvstává problém, že pouze část dat by měla být nahrazena daty nově přichozími. Následkem čehož mohou vlastní čísla kovarianční matice $P^{-1}(k)$ vést k nule a zesílení $P(k)\varphi(k)$ nabývat neomezených hodnot. Algoritmus se navíc stává náchylný na působení šumu. Tento fenomén je znám jako estimator windup.

2.1. PROBLEMATIKA IDENTIFIKACE METODAMI NEJMENŠÍCH ČTVERCŮ

Estimator windup – řeší se modifikací exponenciálního zapomínání na zapomínání zabraňující ztrátě informace nekompensované získáním nové. Tyto techniky jsou označovány jako směrové zapomínání. V uživatelském prostředí je možnost volit včetně zapomínání exponenciálního rovněž zapomínání konstantní popř. adaptivní směrové a zapomínání založené na dekompozici informační matice.

Kovarianční matice $P^{-1}(k)$ by měla být pozitivně definitní. V některých případech vlivem nepřesností, zaokrouhlovacích chyb může nastat, že bude indefinitní a získaný odhad parametrů bude divergovat - tento fakt motivoval k rozvoji tzv. odmocninových filtrů [3], kdy $P^{-1}(k)$ je faktorizována na produkt dvou, popř. tří matic. Identifikační algoritmus pak přímo neobnovuje matici $P^{-1}(k)$, ale její rozklad, čímž zaručuje pozitivní definitnost původní kovarianční matice $P^{-1}(k)$. Rozlišujeme dva typy filtrů. Aplikací Choleskyho dekompozice získáme filtr typu REFIL

$$P(k+1) = Q(k+1)Q^T(k+1) \quad (3)$$

Druhým typem je LDFIL filtr založený na U-D dekompozici ve tvaru

$$P(k+1) = U(k+1)D(k+1)U^T(k+1) \quad (4)$$

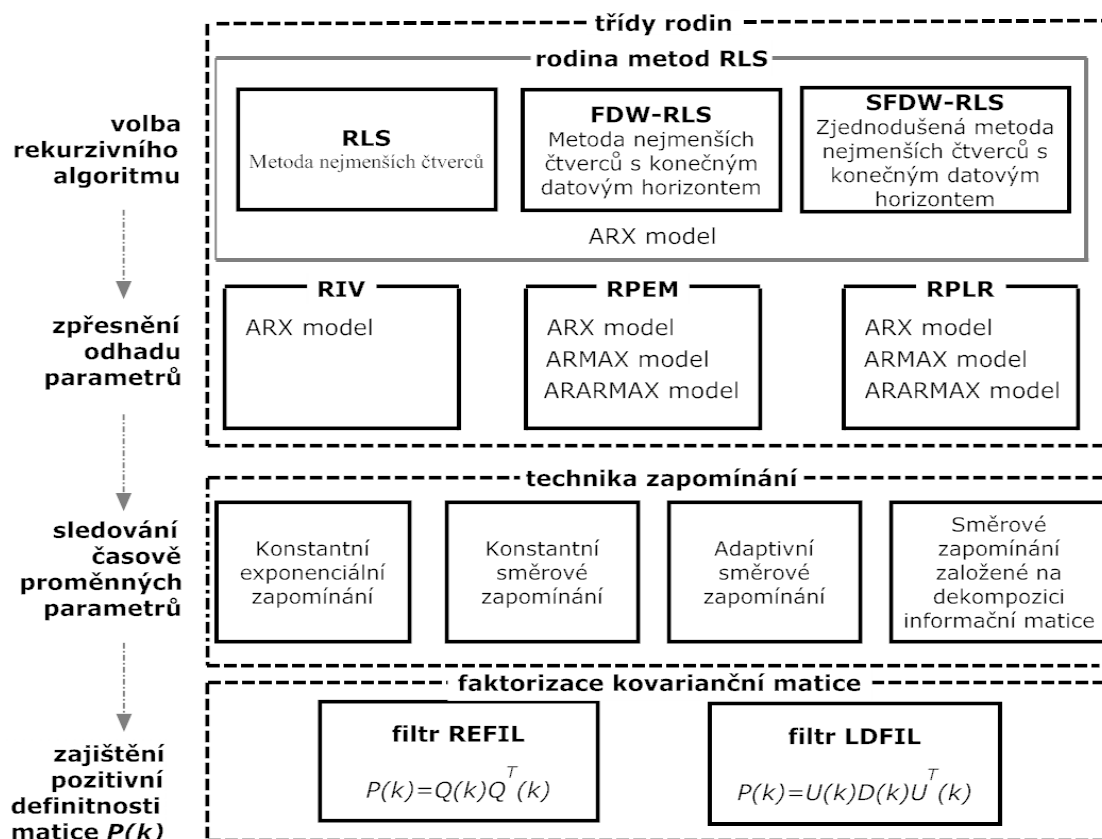
Užitím obou přístupů byly odvozeny vztahy pro metody zahrnující v sobě jak faktorizaci $P^{-1}(k)$ tak současně výše popsané techniky zapomínání a to i pro rekurzivní metody nejmenších čtverců pracujících s horizontem dat konečné délky.

Působení šumu a chyby měření mohou způsobit, že získaný odhad bude vychýlený, což v některých případech vede až k selhání regulátoru – zpřesnění odhadu parametrů lze docílit vhodnou volbou struktury modelu, která nejlépe vystihuje charakter procesu popř. zavedením pomocných instrumentů. V aplikaci je možnost odhadovat parametry regresních ARX, ARMAX a ARARMAX modelů z rodin metod RLS (*rekurzivní metoda nejmenších čtverců*), RIV (*rekurzivní metoda instrumentální proměnné*), RPLR (*rekurzivní metoda pseudolineární regrese*) a RPEM (*rekurzivní metoda predikčních chyb*) [2].

2.2. PROBLEMATIKA IDENTIFIKACE NEURONOVÝMI ESTIMÁTORY

Pro identifikaci neuronovými estimátory byly zvoleny algoritmy Back Propagation a rychleji konvergující Marquardt-Levenberg. V případě modelování procesu jedním neuronem váhy neuronu přímo představují koeficienty hledaného regresního modelu. S gradientními metodami je spojena zejména problematika zajištění konvergence pro soustavy vyšších řádů a ošetření stavu, kdy je proces nedostatečně buzený. Řešení problému co do konvergence parametrů může spočívat v návrhu složitější struktury sítě s adaptivním krokem učení. Potlačení problému přeučení sítě na datech nesoucích nedostatečné množství informace o dynamice systému může být dosaženo vypínáním

identifikace v případě shody horizontu žádaných hodnot s horizontem výstupních veličin ve stanoveném pásmu necitlivosti, např. dle parametru kvantování.



Obrázek 1: Postup sestavení identifikačního algoritmu na bázi metod nejmenších čtverců

3. ZÁVĚR

V rámci semestrální práce bylo ověřeno chování algoritmů z široké řady metod nejmenších čtverců a s prvky umělé inteligence na matematických modelech soustav. Pro modelování neuronovými estimátory byl zvolen algoritmus Back Propagation a jeho modifikace co do dopředného učení Marquardt-Levenberg. Výrazné zlepšení u těchto metod přineslo rozšíření na model ARMAX. Z porovnání vlastností obou přístupů vyplývá, že pokročilejší techniky metod nejmenších čtverců za současného stavu poskytují přesnější a robustnější řešení problematiky identifikace při adaptivním řízení i za relativně velkých hodnot parametru kvantování. Podstatnou nevýhodu gradientních metod představuje obtížnost zamezení uváznutí v lokálním minimu prostoru generovaného vstupním vektorem. Náplní diplomové práce bude ověřování vlastností adaptivních regulátorů na reálných procesech.

LITERATURA

- [1] Pivoňka, P.: Optimalizace regulátorů, Brno, skriptum FEKT VUT, 2005
- [2] Ljung, L.: System identification – theory for user (second edition). Prentice-Hall, Englewood Cliffs, NJ, 1999, ISBN 0-13-656695-2
- [3] Bierman, G. J.: Factorization methods for discrete sequential estimation, Academic Press, New York, 1977