

ADAPTIVE CONTROL WITH NEURAL NETWORK IDENTIFICATION

Petr Malounek

Master Degree Programme (2), FEEC BUT
E-mail: xmalou01@stud.feec.vutbr.cz

Supervised by: Petr Pivoňka

E-mail: pivonka@feec.vutbr.cz

ABSTRACT

This paper describe some self tuning controllers as one category of the adaptive controllers. Identification for this controllers may be recursive method least squares or based on neural networks. This methods of identification are compared. Self tuning controller and discrete equivalent PID controller are compared. All result were achieved in MATLAB-SIMULINK and later all algorithm will implement to program logic controllers B&R. Results achieved simulation on real systems will compared with results achieved from MATLAB-SIMULINK.

1. ÚVOD

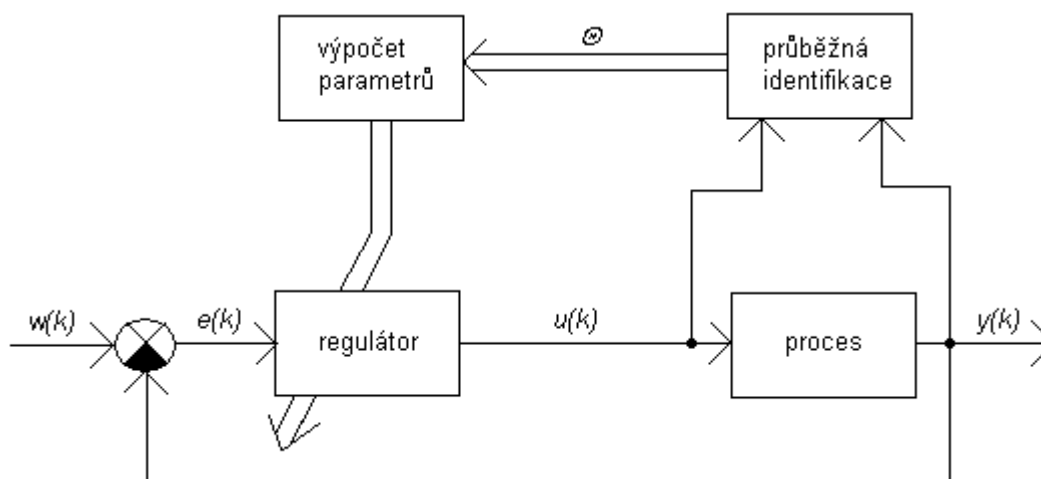
Adaptivní regulátory jsou regulátory, které přizpůsobují své parametry měnícím se parametrům regulovaného procesu v čase. Narozdíl od klasických PID regulátorů se tak dokáží, bez vnějšího zásahu, díky průběžné identifikaci, přizpůsobovat změnám parametrů regulovaného procesu. V tomto článku jsou popsány výsledky dosažené v rámci semestrálního projektu 2 a následující práce na diplomové práci. Účelem bylo srovnat klasickou identifikaci reprezentovanou průběžnou metodou nejmenších čtverců a identifikací založenou na neuronových sítích. Identifikace poté sloužila pro výpočet parametrů samočinně se nastavujících regulátorů, které byly srovnávány s pevně nastaveným diskrétním ekvivalentem PID regulátoru. Výsledky byly dosaženy simulací v prostředí MATLAB – SIMULINK.

2. SAMOČINNĚ SE NASTAVUJÍCÍ REGULÁTORY

Tyto regulátory tvoří jednu kategorii adaptivních regulátorů. Obecné blokové schéma je uvedené na obr.1.

K procesu se přistupuje jako k černé skřínce, u které známe pouze vstup a výstup. Parametry procesu získáváme pomocí identifikace, která může být jednorázová nebo průběžná. Jednorázovou identifikací získáme parametry modelu soustavy ze sady naměřených dat jednorázovým výpočtem. V případě, kdy se mění parametry regulovaného procesu je třeba identifikaci znovu spouštět, abychom získali nové parametry procesu pro nový výpočet parametrů regulátoru. U samočinně se nastavujících regulátorů se spíše používá identifikace průběžná, která neustále vypočítává a upřesňuje parametry modelu soustavy, ze kterého jsou počítány parametry regulátoru. Výpočet parametrů regulátoru může být přímo

z vektoru odhadu parametrů procesu nebo přes modifikované kritérium Zieglera-Nicholse.



Obrázek 1: Obecné schéma samočinně se nastavujícího regulátoru.

3. IDENTIFIKACE

Pro správný výpočet parametrů samočinně se nastavujícího regulátoru je třeba co nejpřesnější odhad parametrů procesu. V případě semestrálního projektu 2 byl použit ARX model prvního, druhého a třetího řádu. Byla použita identifikace průběžnou metodou nejmenších čtverců a identifikace založená na neuronové síti s gradientním učením.

Neuronová síť byla reprezentována jedním neuronem s lineární výstupní funkcí. Vstupní váhy přímo určovaly hodnoty vektoru parametrů modelu. Jediný použitý neuron je právě proto, že je přímo znám vektor parametrů modelu, protože v případě použití více neuronů by se tyto parametry obtížně zjišťovaly nebo by to bylo nemožné. Lineární výstupní funkce je z toho důvodu, aby výstup mohl nabývat jakýchkoliv hodnot.

Při porovnávání výsledků, které byly dosaženy identifikací, na různých dynamických procesech, pomocí metody nejmenších čtverců a neuronové sítě s gradientním učením bylo zjištěno, že gradientní učení je sice velmi jednoduché na implementaci, ale výsledky nebyly tak dobré jako u průběžné metody nejmenších čtverců. Srovnání bylo provedeno porovnáním přechodových charakteristik identifikovaného procesu a modelu. Dále pak byla použita kritéria pro vyhodnocení chyby predikce modelu. Chyba predikce je počítána jako rozdíl výstupu soustavy a predikované hodnoty modelu. Kritérii byla, součet kvadrátů chyby predikce a součet absolutních hodnot chyby predikce násobeného krokem, ve kterém k chybě došlo. Výsledky těchto kritérií ukázaly, že chyba predikce je u metody nejmenších čtverců menší než chyba predikce neuronové sítě s gradientním učením. V diplomové práci bude zkoušeno učení neuronové sítě učením Levenbrg-Marquardt. V rámci semestrálního projektu 2 a diplomové práce je také vytvářeno vizualizační prostředí v MATLABu pro vyhodnocení výsledků identifikace.

4. VÝPOČET PARAMETRŮ REGULÁTORU A REGULÁTOR

Výpočet parametrů regulátoru může být přímo z vektoru parametrů modelu, jak je tomu např. u Dahlinova regulátoru, který byl zkoušen, nebo výpočtem kritického zesílení a periody kritických kmitů a následného použití modifikovaného kritéria Zieglera-Nicholse, kdy se spočtené hodnoty zesílení, derivační a integrační konstanty dosadí do rovnice reguláto-

ru, např. Takahashiho regulátoru.

Algoritmus Dahlinova regulátoru je jednoduchý na implementaci. Výsledky simulací ukázaly, že je použitelný na velmi omezené množství soustav a díky seřizovacímu faktoru je třeba jej ještě správně prvotně nastavit, jinak dojde ke špatnému výpočtu parametrů regulátoru. Takahashiho regulátor byl lepší. Při výpočtu není třeba žádné prvotní nastavení konstant regulátoru. Proto byl také použit v další práci pro srovnávání s pevně nastaveným diskretním ekvivalentem PID regulátoru.

Byl porovnáván Takahashiho regulátor a pevně nastavený diskretní ekvivalent PID regulátoru. Výsledky simulací ukázaly, že pevně nastavený PID regulátor dosahuje lepších výsledků v průběhu přechodného děje v případě, že proces nemění svoje parametry. Je to dáno tím, že konstanty lze dle libosti a požadavku nastavit tak, aby přechodný děj splňoval požadované kritérium na průběh. U adaptivního regulátoru toto není možné, protože je implementován jako algoritmus a výpočet probíhá zcela samostatně. V případě změn parametrů procesu již záleželo na robustnosti nastaveného PID regulátoru a podle toho vypadal průběh přechodného děje. V tomto ohledu vykazoval Takahashiho regulátor lepší výsledky, protože se díky své adaptivitě dokázal přizpůsobit změnám parametrů procesu.

Při srovnání použitých identifikačních metod v adaptivním regulátoru byla lepší identifikace metodou nejmenších čtverců. Bylo to dáno tím, že prováděla lepší odhad parametrů procesu. Při použití metody nejmenších čtverců bylo možno řídit i proces obsahující astatismus. Při použití neuronové sítě se tohoto dosáhnout nepovedlo. Také velmi záleželo na zvolené periodě vzorkování, protože neuronová síť je učena ze souboru předchozích dat, která jsou neustále aktualizována. Nebylo možné použít jednu periodu vzorkování na všechny testované soustavy jako se toho povedlo dosáhnout u metody nejmenších čtverců, ale bylo třeba periodu vzorkování vhodně měnit.

5. ZÁVĚR

Algoritmy, které byly použity pro získání výsledků simulací byly implementovány jako s-funkce ve scriptovém jazyku programu MATLAB. V rámci diplomové práce budou přepsány do jazyka ANSI C, aby je bylo možné implementovat do programovatelných automatů B&R, pro praktické ověření na fyzikálních modelech. Také bude provedeno srovnání výsledků dosažených v simulacích a výsledků dosažených na fyzikálních modelech.

LITERATURA

- [1] Pivoňka, P.: Číslicová řídicí technika, skriptum, VUT FEKT, Brno, 2003
- [2] Bobál, V. a kol.: Praktické aspekty samočinně se nastavujících se regulátorů: algoritmy a implementace, VUTIUM 1999, ISBN 80-214-1299-2
- [3] Malounek, P.: Adaptivní regulátory s principy umělé inteligence v prostředí MATLAB - B&R, Semestrální projekt 2, ÚAMT FEKT VUT, Brno, 2006