

STUDIE ADAPTIVNÍHO REGULÁTORU PRO SYSTÉM S DOPRAVNÍM ZPOŽDĚNÍM

A study of adaptive controller for system with time delay

Veselý Martin

Abstrakt Článek se zabývá aplikací optimalizační metody Gradient Descent pro optimalizaci lineární polynomiální neuronové jednotky LNU jako regulátor pro řízení systému s dopravním zpožděním akčního zásahu. V článku je řešen problém nezávislosti optimalizační funkce a vah neuronu jako regulátor v téměř diskrétním čase. Jako řešení tohoto problému byl sestaven korekční člen v optimalizačním algoritmu který tuto skutečnost zohledňuje.

Klíčová slova HONU; LNU; řízení s referenčním modelem; řízení s dopravním zpožděním

Abstrakt The article deals with application of the Gradient Descent optimization method for the optimization of the linear polynomial neural unit LNU as a controller for controlling the system with a transport delay of the control variable. The article deals with the problem of the independence of the optimization function and the weight of the neuron as a controller in the same discrete time. As a solution to this problem, a correction member has been compiled in an optimization algorithm that takes this into account.

Key words HONU; LNU; Model Reference Control; Control With Time Delay

1. Úvod

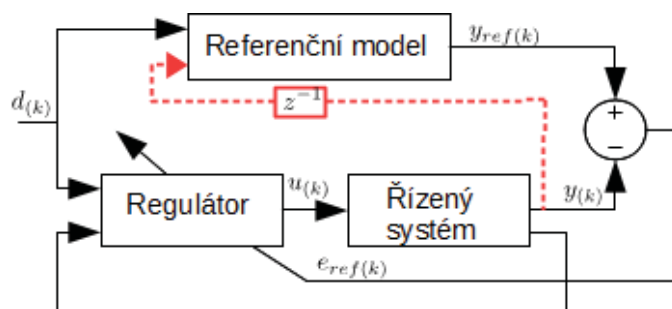
Práce ukazuje aplikaci lineární neuronové jednotky LNU [1] jako diskrétní adaptivní regulátor pro řízení spojitého systému v reálném čase. Adaptivní znamená schopnost regulátoru přizpůsobovat své parametry v reálném čase, během procesu. Pro adaptaci vah neuronu, představující parametry regulátoru, je použita metoda Gradient Descent [2]. Je to optimalizační metoda hledající lokální minima optimalizační funkce. Tato metoda byla vybrána jednak z důvodu, že neuronová jednotka LNU má pouze jeden lokální extrém [3] [4], není tedy třeba aplikovat optimalizační metody hledající globální extrémy. Druhým důvodem je její výpočetní nenáročnost. Není zde třeba počítat inverzní matice, aproximace či provádění více iteračních výpočtů během jednoho časového kroku. Optimalizační metoda GD je tedy vhodná při aplikaci v jednoduchých programovatelných řídicích jednotkách a při řízení rychlých systémů.

V první části je ukázán matematický popis LNU jako regulátor a jako model řízené soustavy. Druhá část se věnuje adaptaci neuronové jednotky jako regulátor. Pro toto učení vah neuronu je jako učitel použit sériově-paralelní referenční model. Je zde interpretována optimalizační metoda Gradient Descent a dále je ukázáno její použití pro řízení systému s dopravním zpožděním akčního zásahu, tedy v případě kdy odchylka mezi výstupem z

referenčního modelu a regulované veličiny nezávisí na akčním zásahu a váhách neuronu v tomtéž diskretním čase. Ve třetí části je pak simulačně ukázáno řízení systému s dopravním zpožděním bez přeučení vah neuronu jako regulátor.

2. HONU jako regulátor a model řízené soustavy

Základní myšlenkou řízení s referenčním modelem je vnutit chování referenčního modelu uzavřenému regulačnímu obvodu [5]. Základy řízení se sériově-paralelním referenčním modelem byli ukázány v [6] a podrobnější popis pro diskretní řízení je v [7]. Základní schéma je zobrazeno na obr.1.



5Obr. 1: Základní schém řízení se sériově-paralelním referenčním modelem

Regulátorem je pak soubor pravidel a funkcí, které toto referenční chování uzavřenému regulačnímu obvodu zaručí. Řízení s LNU jako regulátor vychází z předpokladu, že takovýto soubor pravidel a funkcí lze s dostatečnou přesností aproximovat neuronovou jednotkou LNU. Tentýž předpoklad pak platí i pro regulovaný systém. V této práci je ukázáno použití LNU jako regulátor a model řízeného systému.

Lineární neuronová jednotka má lineární agregační funkci a v této práci není uvažována přenosová funkce. Výpočet výstupu z LNU jako regulátor (akční zásah $u(k)$) je (1).

$$u(k) = \mathbf{v}(k) \cdot \xi(k) \quad (1)$$

Kde $\xi(k)$ je vstupním vektorem do LNU jako regulátor v diskretním čase k . Může se skládat z měřených hodnot řízené veličiny y a žádaných hodnot d (5). \mathbf{v} je vektorem vah neuronu.

Za účelem znalosti relace mezi akčními zásahy v příslušných diskretních časech a aktuální hodnotou regulované veličiny byl sestaven model ve tvaru (2). Kde $\mathbf{x}_y(k)$ a $\mathbf{x}_u(k)$ představují vstupní vektory do modelu (3) a (4). w_1 , \mathbf{w}_y a \mathbf{w}_u jsou váhy LNU jako model řízení soustavy.

$$y_n(k) = w_1 + \mathbf{w}_y \cdot \mathbf{x}_y(k) + \mathbf{w}_u \cdot \mathbf{x}_u(k) \quad (2)$$

$$\mathbf{x}_y(k) = [y(k-1), \dots, y(k-n_y)]^T \quad (3)$$

$$\mathbf{x}_u(k) = [u(k-\tau), \dots, u(k-\tau-n_d+1)]^T \quad (4)$$

je dopravní zpoždění řízeného systému. τ

$$\xi(k) = [1, y(k-1), \dots, y(k-m_y), d(k), \dots, d(k-m_d+1)]^T \quad (5)$$

3. Učení regulátoru metodou Gradient descent

Optimalizační metoda Gradient Descent nebo též známá pod názvem Steepest Descent hledá lokální minima. Pro LNU jako regulátor ji lze zapsat následovně:

$$v_{i(k+1)} = v_{i(k)} - \mu^{(k)} \cdot \frac{\partial Q^{(k)}}{\partial v_{i(k)}} \quad (6)$$

Kde μ je součinitel rychlosti učení. Rovnici (6) lze interpretovat následovně: Váhy $\mathbf{v}_{(k+1)}$ jsou počítány z hodnot $\mathbf{v}_{(k)}$ v předchozím čase proti směru gradientu optimalizační funkce $Q^{(k)}$. $Q^{(k)}$ je sestavena tak, aby nabývala svého minima, právě když je referenční odchylka $e_{ref(k)}$ mezi referenčním signálem $y_{ref(k)}$ a regulovanou veličinou $y(k)$ (7) nulová.

$$Q^{(k)} = \frac{1}{2} (y_{ref(k)} - y(k))^2 \quad (7)$$

Aby bylo možné vypočítat gradient optimalizační funkce (7) v (6), je předpokládáno, že chování modelu (2) se dostatečně blíží chování reálného systému a tedy platí (8).

$$y_{n(k)} \approx y(k), \forall k \quad (8)$$

Dosazením LNU jako regulátor (1) v příslušných časech do vstupního vektoru akčních zásahů (4) dostáváme:

$$\mathbf{x}_{u(k)} = \begin{bmatrix} u_{(k-\tau)} = \mathbf{v}_{(k-\tau)} \cdot \xi_{(k-\tau)} \\ \vdots \\ u_{(k-\tau-n_u+1)} = \mathbf{v}_{(k-\tau-n_u+1)} \cdot \xi_{(k-\tau-n_u+1)} \end{bmatrix} \quad (9)$$

Dosazením (9) do (2) je zřejmé, že nelze provést gradient v (6) neboť zde nejsou obsaženy váhy $\mathbf{v}_{(k)}$. Gradient by tak vyšel vždy nulový. Optimalizační funkce (7) není tedy závislá na vahách \mathbf{v} v čase k . Vzniklý problém je řešen pomocí tzv. fiktivního výstupu z modelu $\tilde{y}_{n(k)}$, který by nastal kdyby všechny opožděné akční zásahy v (4) byly počítány z aktuálních vah $\mathbf{v}_{(k)}$. Fiktivní vstupní vektor do modelu $\tilde{\mathbf{x}}_{u(k)}$ lze potom napsat dosazením aktuálních vah do (9) následovně:

$$\tilde{\mathbf{x}}_{u(k)} = \begin{bmatrix} \tilde{u}_{(k-\tau)} = \mathbf{v}_{(k)} \cdot \xi_{(k-\tau)} \\ \vdots \\ \tilde{u}_{(k-\tau-n_u+1)} = \mathbf{v}_{(k)} \cdot \xi_{(k-\tau-n_u+1)} \end{bmatrix} \quad (10)$$

Fiktivní výstup z modulu $\tilde{y}_{n(k)}$ je počítán podle (2) dosazením (10):

$$\tilde{y}_{n(k)} = w_1 + \mathbf{w}_y \cdot \tilde{\mathbf{x}}_{y(k)} + \mathbf{w}_u \cdot \tilde{\mathbf{x}}_{u(k)} \quad (11)$$

Nyní lze pomocí (11) sestavit optimalizační funkci závislejší pouze na aktuálních vah $\mathbf{v}_{(k)}$:

$$Q^{(k)} = \frac{1}{2} (y_{ref(k)} - \tilde{y}_{n(k)})^2 \quad (12)$$

Požítím (12) můžeme gradient v (6) vypočítat následovně:

$$\frac{\partial Q^{(k)}}{\partial \mathbf{v}_{(k)}} = -\mu^{(k)} \cdot (y_{ref(k)} - w_1 - \mathbf{w}_y \cdot \tilde{\mathbf{x}}_{y(k)} - \mathbf{w}_u \cdot \tilde{\mathbf{x}}_{u(k)}) \cdot \mathbf{w}_u \cdot J^{(k)} \quad (13)$$

Kde J je Jacobiho matice:

$$J_{(k)} = \begin{bmatrix} \frac{\partial \tilde{\mathbf{x}}_{u(k-\tau)}}{\partial v_{1(k)}} & \dots & \frac{\partial \tilde{\mathbf{x}}_{u(k-\tau-n_u+1)}}{\partial v_{1(k)}} \\ \vdots & & \vdots \\ \frac{\partial \tilde{\mathbf{x}}_{u(k-\tau)}}{\partial v_{m(k)}} & \dots & \frac{\partial \tilde{\mathbf{x}}_{u(k-\tau-n_u+1)}}{\partial v_{m(k)}} \end{bmatrix} \quad (14)$$

Schopnost učení (1) bude ovlivněna dodržěním předpokladu (8). Což znamená, že učení LNU jako regulátor bude závislé na kvalitě naučení vah modelu w_1 , \mathbf{w}_y a \mathbf{w}_u . Pro zvýšení schopnosti učení je dále sestaven tzv. korekční člen $\delta y_{(k)}$, umožňující použít naměřenou regulační veličinu namísto členů obsahující \mathbf{w}_y a w_1 v (13). Korekční člen byl sestaven jako rozdíl mezi regulovanou veličinou a fiktivním výstupem z modelu:

$$\delta y_{(k)} = y_{(k)} - \tilde{y}_{n(k)} \quad (15)$$

Porovnáním členů v (9) a (10) lze sestavit obdobný vztah i pro vstupní vektory do modelů:

$$\delta \mathbf{x}_{u(k)} = \mathbf{x}_{u(k)} - \tilde{\mathbf{x}}_{u(k)} \quad (16)$$

Pro určení členu $\delta x_{(k)}$ je dále nezbytné znát vztah mezi vahami $\mathbf{v}_{(k)}$ a $\langle \mathbf{v}_{(k-\tau)}, \mathbf{v}_{(k-\tau-n_u+1)} \rangle$. Tyto závislosti lze získat z úpravy (6) do tvaru (17) a následným dosazováním rovnice sama do sebe v jednotlivých diskretních časech (18).

$$v_{i(k-1)} = v_{i(k)} + \mu_{(k-1)} \cdot \frac{\partial Q_{(k-1)}}{\partial v_{i(k-1)}} \quad (17)$$

$$v_{i(k-n)} = v_{i(k)} + \sum_{i=1}^n \mu_{(k-n)} \cdot \frac{\partial Q_{(k-n)}}{\partial v_{i(k-n)}} \quad (18)$$

Dosazením (18) do (9) v daných časech dostaneme:

$$\mathbf{x}_{u(k)} = \begin{bmatrix} \left(\mathbf{v}_{(k)} + \sum_{i=1}^{\tau} \mu_{(k-i)} \cdot \frac{\partial Q_{(k-i)}}{\partial \mathbf{v}_{(k-i)}} \right) \cdot \xi_{(k-\tau)} \\ \vdots \\ \left(\mathbf{v}_{(k)} + \sum_{i=1}^{\tau+n_u-1} \mu_{(k-i)} \cdot \frac{\partial Q_{(k-i)}}{\partial \mathbf{v}_{(k-i)}} \right) \cdot \xi_{(k-\tau-n_u+1)} \end{bmatrix} \quad (19)$$

Porovnáním členů v (10) a (18) pak lze $\delta x_{(k)}$ v (16) vypočítat následovně:

$$\delta x_{(k)} = \begin{bmatrix} \sum_{i=1}^{\tau} \mu_{(k-i)} \cdot \frac{\partial Q_{(k-i)}}{\partial \mathbf{v}_{(k-i)}} \cdot \xi_{(k-\tau)} \\ \vdots \\ \sum_{i=1}^{\tau+n_u-1} \mu_{(k-i)} \cdot \frac{\partial Q_{(k-i)}}{\partial \mathbf{v}_{(k-i)}} \cdot \xi_{(k-\tau)} \end{bmatrix} \quad (20)$$

A následně korekční člen $\delta y_{(k)}$ lze vypočítat pomocí (20):

$$\delta y_{(k)} = \mathbf{w}_u \cdot \delta \mathbf{x}_{u(k)} \quad (21)$$

Dosazením korekčního členu (21) do (15) a posléze do (13) dostáváme výslednou rovnici pro adaptaci vah LNU jako regulátor (22) nezávislou na w_1 a \mathbf{w}_y .

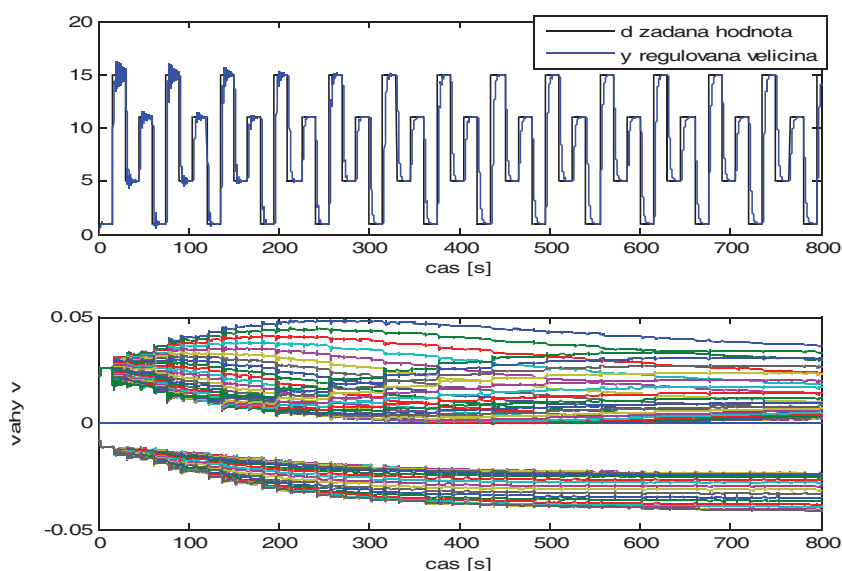
$$\mathbf{v}_{(k+1)} = \mathbf{v}_{(k)} + \mu_{(k)} (y_{ref(k)} - y_{(k)} + \mathbf{w}_u \cdot \delta \mathbf{x}_{u(k)}) \cdot \mathbf{w}_u \cdot J_{(k)} \quad (22)$$

4. Experimentální analýza

Vlastnosti navrženého algoritmu byly testovány simulačně při řízení lineárního systému s dopravním zpožděním. Parametry řízeného systému a referenčního modelu jsou uvedeny v tab.1.

Tabulka 1. Vlastnosti řízeného a referenčního modelu

	Řízený model	Referenční model
Statické zesílení	3.3	1
kořeny	$-0.4 \pm 2.7i$	$-2; -0.7$
dopravní zpoždění	0.3s	0.3s



Obr. 2: Simulace řízení s učením vah regulátoru

Vzorkovací perioda byla zvolena 0.05s. Simulace probíhala se přeúčeným modelem řízené soustavy použito ve tvaru (2) a nulovými nastavením vah LNU jako regulátor $v_{\forall i \forall j}(k) = 0$. Výsledky simulace jsou ukázány na obr.2.

5. Závěr

Článek ukazuje možnost aplikace optimalizační metody Gradient Descent pro adaptaci vah LNU jako regulátor. Aby bylo možné aplikovat metody pro regulovaný systém s dopravním zpožděním akčního zásahu, byl navržen korekční člen v optimalizační funkci. Druhá část pak byla věnována simulaci řízení systému s dopravním zpožděním.

Literatura

- [1] I. Bukovsky, Z.-G. Hou, J. Bila, and M. M. Gupta, "Foundation of Notation and Classification of

- Nonconventional Static and Dynamic Neural Units,” 2007, pp. 401–407.
- [2] G. Arfken, “The Method of Steepest Descents,” *The method of steepest descents*, vol. 1985, no. 3.
 - [3] I. Bukovsky and N. Homma, “An Approach to Stable Gradient Descent Adaptation of Higher-Order Neural Units,” *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 2016, no. DOI:10.1109/TNNLS.2016.2572310.
 - [4] I. Bukovsky, N. Homma, L. Smetana, R. Rodriguez, M. Mironovova, and S. Vrana, “Quadratic neural unit is a good compromise between linear models and neural networks for industrial applications,” 2010, pp. 556–560.
 - [5] I. D. Landau, R. Lozano, M. M’Saad, and A. Karimi, *Adaptive Control: Algorithms, Analysis and Applications*. Springer Science & Business Media, 2011.
 - [6] V. Kasparian and C. Batur, “Model reference based neural network adaptive controller,” *ISA Trans.*, vol. 37, no. 1, pp. 21–39, Březen 1998.
 - [7] M. Veselý and I. Bukovský, “Adaptivní neuroregulátor se sériově-paralelním referenčním modelem,” *ARTEP*, vol. 2006.



Selected article from
Tento dokument byl publikován ve sborníku

**Nové metody a postupy v oblasti přístrojové techniky,
automatického řízení a informatiky 2017**
**New Methods and Practices in the Instrumentation,
Automatic Control and Informatics 2017**
29. 5. – 30. 5. 2017, Svatý Jan pod Skalou

ISBN 978-80-01-06300-2

Web page of the original document:

<http://control.fs.cvut.cz/nmp>
<http://iat.fs.cvut.cz/nmp/2017.pdf>

Obsah čísla/individual articles:

<http://iat.fs.cvut.cz/nmp/2017/>