

# **NELINEÁRNÍ ADAPTABILNÍ NEURO-REGULÁTOR**

## **Nonlinear adaptive Neuro-Controller**


**Ladislav Smetana**

**Abstrakt:** Nelineární adaptabilní Neuro-regulátor byl navržen pro regulaci nelineárních soustav. Neuro-regulátor pracuje na principu stavové zpětné vazby s využitím dvou jednotek HONNU z nichž Diskrétní Dynamická Kvadratická Neuronová Jednotka je připojena paralelně k nelineárnímu systému a využívá se k identifikaci vlastností a dynamiky nelineárního reálného systému, Statická Diskrétní Kvadratická Neuronová Jednotka je zapojena ve zpětné vazbě jako adaptabilní stavový regulátor. Obě neuronové jednotky se neustále adaptují a tím zvyšují přesnost a kvalitu regulace. Zavedením zpětné vazby formou proporcionálního členu bylo dosaženo velice rychlého, kvalitního a robustního regulačního procesu pro celý rozsah regulované veličiny. Neuro-regulátor byl aplikován a úspěšně vyzkoušen na nelineární laboratorní úloze Batyskaf.

**Key words:** Neuron, Neuronová jednotka, Nelineární systémy, adaptabilní řízení, HONNU, QNU

### **1. Úvod**

Protože nelineární dynamické neuronové jednotky mají velice dobrou schopnost adaptace a s tím spojenou vlastnost naučit se vlastnosti a dynamiku reálného nelineárního systému, nabízí se možnost jejich uplatnění při regulaci reálných nelineárních soustav, kde klasické regulátory z mnoha důvodů selhávají. Nejlepším regulátorem pro nelineární soustavu bude regulátor, který zná její vlastnosti nebo matematický popis. Neuro-regulátor složený z neuronových jednotek lze použít i pro neznámé reálné procesy, protože neuronové jednotky jsou schopny si samy vytvořit model neznámé reálné soustavy a průběžnou neustálou adaptací tento model ještě zpřesňují. Neuro-regulátor (Obr. 1), aplikovaný na laboratorní soustavu Batyskaf, obsahuje diskrétní dynamickou kvadratickou neuronovou jednotku s vnitřní dynamikou druhého řádu (Discrete Dynamic-Second-Order-Extended QNU [DDSOE-QNU]), která slouží k identifikaci a vytvoření modelu reálné nelineární soustavy druhého řádu (Batyskafu). Diskrétní statická kvadratická neuronová jednotka (Discrete Static QNU [DS-QNU]) je zapojena jako zpětnovazební stavový Neuro-regulátor. Identifikaci provádějící DDSOE-QNU předává informace o vytvořeném modelu soustavy Neuro-regulátoru (DS-QNU) a tím zajišťuje schopnost dobré regulace v celém rozsahu regulované veličiny nelineární soustavy.



Obr. 1 – Schéma regulace reálné nelineární soustavy Neuro-regulátorem

## 2. Odvození a popis Neuro-regulátoru

Matematický popis celého uzavřeného regulačního obvodu získáme následovně. Funkce dynamické neuronové jednotky (identifikace) je uvedena v rovnici (2) a funkce statické neuronové jednotky (regulátor) v rovnici (3).

$$\text{Definice: } D\{y_{(k)}\} \equiv y_{(y+1)} \quad (1)$$

$$y_{(k)} \equiv y_{idn(k)} = DD\{f_{idn}(u_{(k)}, y_{(k)}, y_{(k+1)}, W_{idn})\} \quad (2)$$

$$y_{reg(k)} = f_{reg}(y_{(k)}, y_{(k-1)}, W_{reg}) \quad (3)$$

Akční veličina  $u_{(k)}$  je rozdílem požadované veličiny  $w_{(k)}$  a veličiny  $y_{reg(k)}$ , rovnice (4). Rovnici (4) pak dosadíme zpět do rovnice (2) a z takto získané rovnice (5) vyvodíme pomocí metody Back-Propagation (BP) (6)(7) vztahy pro změny jednotlivých neurálních vah, které se mění v každém kroku.

$$u_{(k)} = w_{(k)} - y_{reg(k)} \quad (4)$$

$$y_{(k)} = DD\{f_{idn}(w_{(k)} - y_{reg(k)}, y_{(k)}, y_{(k+1)}, W_{idn})\} \quad (5)$$

Back-Propagation je Gradientová metoda výpočtu neurálních vah, kdy se jednotlivé neurální váhy upravují v každém kroku proti směru gradientu chyby rozdílu mezi správnou

výstupní hodnotou z reálného systému  $y_{r(k)}$  a vypočtenou výstupní hodnotou z neuronové jednotky  $y_{n(k)}$  tak, že  $e_{(k)} = y_{r(k)} - y_{n(k)}$ .

$$\Delta w_{i,j} = -\mu \frac{\partial J}{\partial w_{i,j}}, \text{ kde } J = \frac{1}{2} e^2 \quad (6)$$

$$\Delta w_{i,j} = \mu \cdot e \cdot DD \left\{ \frac{\partial y_{(k)}}{\partial w_{i,j}} \right\} \quad (7)$$

Výsledný rozepsaný obecný vztah pro výpočet změn neurálních vah Neuro-regulátoru je uveden v rovnici (8). Rozepsané eagrační funkce pro jednotlivé neuronové jednotky jsou uvedeny v (9) a (10).

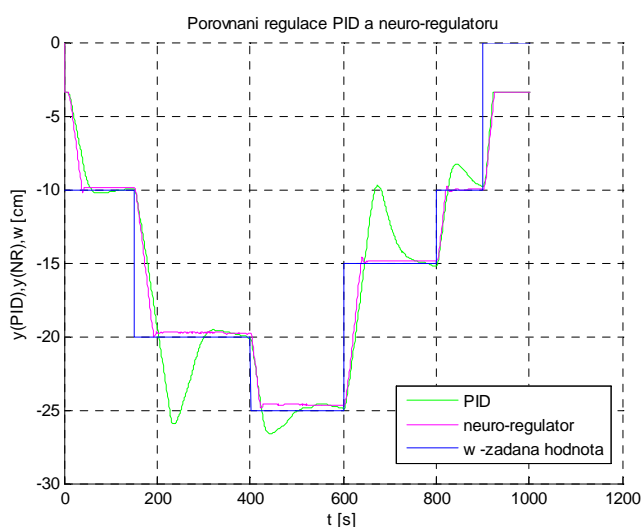
$$\Delta w_{i,j} = \mu \cdot e \cdot DD \left\{ \frac{\partial y_{(k)}}{\partial y_{reg(k)}} \cdot \frac{\partial y_{reg(k)}}{\partial w_{i,j}} \right\} = \mu \cdot e \cdot DD \left\{ \frac{\partial y_{(k)}}{\partial u_{(k)}} \cdot \frac{\partial u_{(k)}}{\partial y_{reg(k)}} \cdot \frac{\partial y_{reg(k)}}{\partial w_{i,j}} \right\} \quad (8)$$

$$y_{(k)} \approx f_{idn(k)} = w_{00} + w_{01}u_{(k)} + w_{02}y_{(k)} + w_{03}y_{(k+1)} + w_{11}u_{(k)}^2 + w_{12}u_{(k)}y_{(k)} + w_{13}u_{(k)}y_{(k+1)} + w_{22}y_{(k)}^2 + w_{23}y_{(k)}y_{(k+1)} + w_{33}y_{(k+1)}^2 \quad (9)$$

$$f_{reg(k)} = w_{00} + w_{01}y_{(k)} + w_{02}y_{(k-1)} + w_{11}y_{(k)}^2 + w_{12}y_{(k)}y_{(k-1)} + w_{22}y_{(k-1)}^2 \quad (10)$$

### 3. Výsledky a shrnutí

Nelineární adaptabilní Neuro-regulátor se velice dobře uplatnil při praktické regulaci reálné nelineární laboratorní úlohy Batyskaf. Neuro-regulátor je schopný regulovat v celém rozsahu regulované soustavy, naopak klasický PID regulátor lze v nelineárním reálném systému použít jen pro velice úzké okolí pracovního bodu, pro který jsou jeho parametry nastaveny. Pokud bychom chtěli obstojně regulovat reálnou nelineární úlohu Batyskaf pomocí PID regulátoru, tak bychom museli parametry PID regulátoru měnit a regulátor ladit postupně s měnící se hloubkou ponořeného batyskafu, což je prakticky těžko proveditelné.



Obr. 2 - Porovnání regulace PID a Neuro-regulátoru (PID regulátor vyladěn na hloubku 10 cm)

Neuro-regulátor se ukázal také jako velice robustní nástroj, protože výsledky regulačního pochodu měly velice malý nebo žádný vliv na změny parametrů soustavy (například velikost vzduchové bubliny v batyskafu). Na Obr. 2 je zobrazeno porovnání regulace PID regulátoru a Neuro-regulátoru, kde PID regulátor byl seřízen pro hloubku 10 cm.

### **Acknowledgement**

This research has been conducted on the Department of Instrumentation and Control Engineering, Faculty of Mechanical Engineering, Czech Technical University in Prague and has been supported by means of Research Grant MSM CR No. 2B06023.

### **References**

- [1] Bíla, J.: Umělá inteligence a neuronové sítě v aplikacích. Skripta Fakulta strojní ČVUT Praha, 1998.
- [2] Bukovsky, I.: Modeling of Complex Dynamic Systems by Nonconventional Artificial Neural Architectures and Adaptive Approach to Evaluation of Chaotic Time Series. Ph.D. Thesis, Faculty of Mechanical Engineering, CTU in Prague, 2007.
- [3] Bukovsky, I., Bíla, J.: „Basic Classification of Nonconventional Artificial Neural Units” (In Czech), *Proceedings of Seminar Nové Hrady*, Czech Technical University in Prague, FME, Czech Republic, 2007, pp. 76-80, ISBN: 978-80-01-03747-8
- [4] Bukovsky, I., Anderle, F., Smetana, L.: “Quadratic Neural Unit for Adaptive Prediction of Transitions among Local Attractors of Lorenz System”, accepted paper for 2008 *IEEE International Conference on Automation and Logistics*, Qingdao, China, 2008.

### **Kontaktní adresa**

U12110, České vysoké učení technické v Praze, Fakulta strojní 16607, Praha 6, Technická 4, Česká republika, +420-22435-2529, Ladislav.Smetana@fs.cvut.cz