

# MODELOVANIE A RIADENIE SYSTÉMOV POMOCOU NEURÓNOVÝCH SIETÍ S ORTOGONÁLNymi FUNKCIAMI V PROSTREDÍ MATLAB

*Slavomír Kajan*

Ústav riadenia a priemyselnej informatiky, Fakulta elektrotechniky a informatiky,  
Slovenská technická univerzita v Bratislave, Slovenská republika

## Abstrakt

**Tento článok opisuje všeobecnú aplikáciu v prostredí Matlab pre modelovanie a riadenie systémov pomocou neurónových sietí s ortogonálnymi aktivačnými funkciami (NSOAF). Metóda modelovania pomocou NSOAF využíva vlastnosti ortogonálnych funkcií, z ktorých je vytvorená nová štruktúra neurónovej siete. V prostredí Matlab/Simulink boli vytvorené funkcie a programy s používateľským prostredím, umožňujúce riešiť rôzne aplikácie modelovania a riadenia systémov pomocou NSOAF.**

## 1 Úvod

V súčasnej literatúre sa často rieši problém získania takého modelu systému, ktorý by zabezpečoval dostatočnú kvalitu riadenia aj pre nelineárne a časovo variantné systémy, pri malom množstve apriórnych informáciách o riadenom procese. Ako perspektívne sa v oblasti modelovania nelineárnych systémov javí použitie umelých neurónových sietí (UNS), ktoré umožňujú vytvárať veľmi kvalitné modely. Na modelovanie systémov sú najčastejšie používané UNS typu "Perceptron", ale v súčasnosti sa čoraz viac objavujú aplikácie s NSOAF.

V predloženom príspevku je riešená problematika modelovania a riadenia systémov pomocou NSOAF. V prostredí Matlab boli vytvorené funkcie a programy s používateľským prostredím, ktoré slúžia na vytvorenie štruktúry NSOAF, tréning, testovanie a simuláciu výstupu neurónovej siete. Vytvorené programy a simulačné schémy sú pomocou NSOAF schopné riešiť nasledovné aplikácie: identifikáciu koeficientov Fourierového radu harmonického signálu, identifikáciu frekvenčnej charakteristiky procesu, off-line a on-line modelovanie nelineárnych systémov, modelovanie dynamických systémov v reálnom čase a prediktívne riadenie simulačných modelov procesov.

## 2 Princíp modelovania systémov pomocou NSOAF

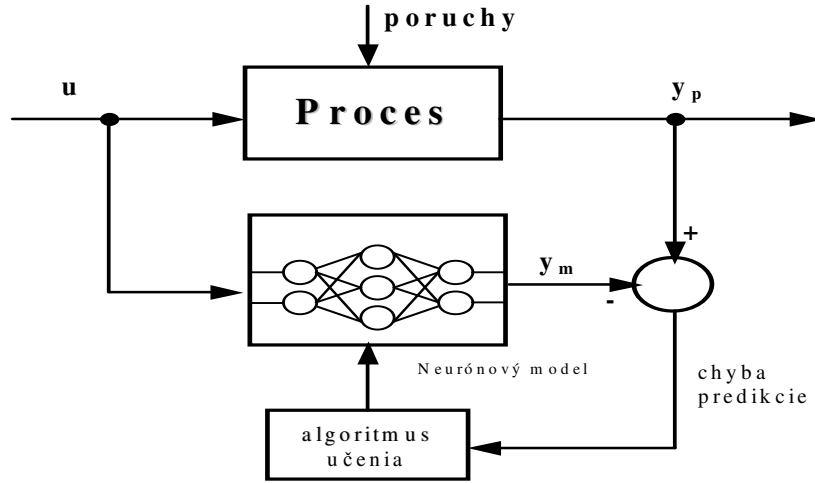
Základom modelovania systémov pomocou umelých neurónových sietí (UNS) sú ich veľmi dobré aproximčné vlastnosti. Potom na základe vstupno-výstupných údajov z procesu je UNS postupným učením schopná aproximovať chovanie sa daného procesu (Obrázok 1). Neurónový model procesu je reprezentovaný NSOAF, ktorá môže byť predtrénovaná pri off-line modelovaní. Úlohou NSOAF je aproximovať výstup procesu v k-tom kroku na základe predchádzajúcich hodnôt vstupu a výstupu procesu.

Potom riadený proces môže byť opísaný nasledovným modelom:

$$y_p(k) = f[y_p(k-1), y_p(k-2), \dots, y_p(k-n_y), u(k-1), u(k-2), \dots, u(k-n_u)] \quad (1)$$

kde  $u$ - vstupná veličina procesu,  $y_p$ - výstupná veličina procesu,  $n$ - rád  $y_p$ ,  $m$ - rád  $u$ ,  $f$ - nelineárna funkcia,  $k$ - diskretný čas ( $t = k * T_{vz}$ ,  $T_{vz}$  je perióda vzorkovania).

Na obrázku 1 je znázornená bloková schéma modelovania systému umelou neurónovou sieťou. Neurónový model je umiestnený paralelne s procesom a chyba (prediction error) je použitá ako tréningový signál siete pre algoritmus učenia. Pri on-line modelovaní algoritmus učenia vykonáva priebežnú adaptáciu váh neurónového modelu na základe aktuálnych hodnôt zodpovedajúcich veličín systému. Na učenie NSOAF sú použité modifikované metódy najmenších štvorcov a metóda prostého gradientu [2].



Obrázok 1: Bloková schéma modelovania procesu umelou neurónovou sieťou

### 3 Štruktúra neurónovej siete s ortogonálnymi aktivačnými funkciami

Neurónová sieť s ortogonálnymi aktivačnými funkciami má trojvrstvovú neurónovú štruktúru obsahujúcu vstupnú vrstvu, výstupnú vrstvu a skrytú vrstvu (obrázok 2) [1, 2, 5].

Skrytá vrstva sa skladá z neurónov s ortogonálnymi aktivačnými funkciami, kde boli použité Čebyševove, Laguerrove, Hermitove a Legendrove polynómy. Aktivačné funkcie pre tieto neuróny patria k rovnakej skupine ortogonálnych funkcií a žiadne dva neuróny nemajú rovnaký rád aktivačnej funkcie. Vstupná a výstupná vrstva sa skladá z lineárnych neurónov. Váhy medzi vstupnou a skrytou vrstvou sú fixné a závisia od použitých ortogonálnych aktivačných funkciách.

Uzly napravo od ortogonálnych neurónov realizujú súčin ( $\Pi$ ). Každý  $\Pi$  uzol má  $m$  vstupných signálov z rozdielnych vstupných blokov. Tieto  $\Pi$  uzly sú považované za časť skrytej vrstvy, pretože tam nie sú žiadne váhové operácie medzi ortogonálnymi neurónmi a  $\Pi$  uzlami.

Výstup siete  $\left[ \hat{y}(\bar{x}, \hat{w}) \right]$  je daný lineárnou kombináciou váh aktivačných funkcií

$$\hat{y}(\bar{x}, \hat{w}) = \sum_{n_1=0}^{(N_1-1)} \cdots \sum_{n_m=0}^{(N_m-1)} \hat{w}_{n_1 \dots n_m} \phi_{n_1 \dots n_m}(\bar{x}) = \bar{\Phi}^T(\bar{x}) \hat{w}, \quad (2)$$

kde  $\bar{x} = [x_1 x_2 \dots x_m]^T$  je  $m$ - dimenzionálny vstupný vektor,  $N_i$  je číslo neurónu asociovaného s  $i$ -tým vstupom a  $\hat{w}$  sú váhy medzi skrytou a výstupnou vrstvou. Funkcie  $\phi_{n_1 \dots n_m}(\bar{x})$  sú ortogonálne funkcie v  $m$ - dimenzionálnom priestore získané pomocou vzťahu

$$\phi_{n_1 \dots n_m}(\bar{x}) = \prod_{i=1}^m \phi_{n_i}(x_i), \quad (3)$$


kde  $\phi_i$  sú ortogonálne funkcie implementované v každom skrytom neuróne.  $\bar{\Phi}(\bar{x})$  a  $\hat{w}$  transformujú vstupný vektor a váhy, respektíve,  $n$ - dimenzionálny vektor váh, kde  $n$  je vyjadruje vzťah:

$$n = \prod_{i=1}^m N_i \quad (4)$$

Ako je zrejme zo vzťahu (4) počet adaptovaných váh narastá s počtom vstupov neurónovej siete a s počtom použitých ortogonálnych funkcií pre jeden vstup. Tento počet je možné znížiť tak, že do vektora  $\bar{\Phi}(\bar{x})$  nezahrnieme všetky výstupy  $\phi_{i_1} \cdot \phi_{i_2} \cdot \phi_{i_m}$  z  $\pi$ -uzlov, ale iba tie pre ktoré platí:

$$i_1 + i_2 + \dots + i_m \leq r \quad \text{pre súčin } \phi_{i_1} \cdot \phi_{i_2} \cdot \phi_{i_m} \quad (5)$$

kde  $r = \max(N_i - 1)$ .  $N_i$  je maximálny rád použitých ortogonálnych funkcií pre vstup  $i$ .



Obrázok 2: Štruktúra neurónovej siete s ortogonálnymi aktivačnými funkciami

#### 4 Prediktívne riadenie s neurónovým modelom

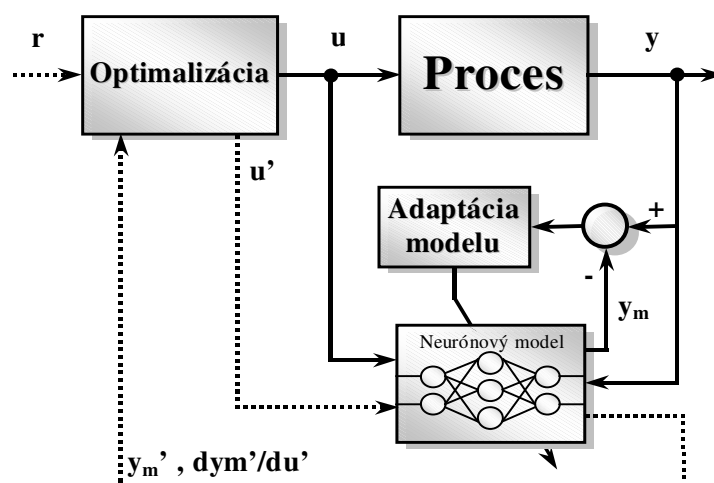
Neurónový model systému vytvorený pomocou NSOAF je ďalej využívaný pri prediktívnom riadení na predikciu výstupu systému pri optimalizácii riadiaceho zásahu. V tejto časti príspevku je opísaný princíp prediktívneho riadenia s neurónovým modelom, ktorý umožňuje priebežnú adaptáciu váh modelu na základe aktuálnych hodnôt vstupu a výstupu procesu. Algoritmus navrhovaného prediktívneho regulátora je možné rozdeliť do dvoch funkčných blokov: [2, 4]

##### 1. Blok identifikácie parametrov riadeného procesu:

Tu prebieha proces učenia neurónového modelu, ktorého cieľom je nájdenie takých váh neurónovej siete, ktoré zaručujú ekvivalentné dynamické chovanie modelu a procesu. Na učenie NSOAF sú použité rekurzívne metódy najmenších štvorcov.

## 2. Blok syntézy riadenia:

Syntéza regulátora používa návrh parametrov regulátora pomocou neurónového modelu, získaného on-line identifikáciou tak, akoby to bol skutočný riadený objekt. Na obrázku 3 je architektúra prediktívneho riadenia, ktorá na realizáciu riadiaceho zásahu používa optimalizáciu účelovej funkcie na základe predikcie výstupu systému pomocou NSOAF. Optimalizácia účelovej funkcie je realizovaná metódou prostého gradientu alebo Newton-Raphsnovou metódou.[2, 4]



Obrázok 3: Architektúra prediktívneho riadenia s adaptáciou neurónového modelu.

## 5 Realizácia NSOAF v prostredí Matlab

V prostredí Matlab boli vytvorené funkcie a programy s používateľským prostredím pre modelovanie a riadenie systémov pomocou NSOAF, ktorých zoznam sa nachádza v Tab.1. Základné funkcie slúžia na vytvorenie štruktúry NSOAF, tréning, testovanie a simuláciu výstupu neurónovej siete. Neurónová sieť je realizovaná dátovou štruktúrou, ktorej jednotlivé položky určujú vlastnosti UNS (Tab.2). [2, 8]. Túto štruktúru je možné vytvoriť funkciou *newNNOAF* vtedy, keď začíname pracovať s neurónovou sieťou. Niektoré jej prvky sú modifikované procesom učenia.

Tabuľka 1: Zoznam programov pre modelovanie a riadenie systémov pomocou NSOAF


newNNOAF	Funkcia na vytvorenie NSOAF štruktúry
trainNNOAF	Funkcia na off-line tréning NSOAF
testNNOAF	Funkcia na off-line testovanie NSOAF
simNNOAF	Funkcia na simuláciu výstupu NSOAF
modelNNOAF	Funkcia realizujúca on-line modelovanie systému v simulačnej schéme
controlNNOAF	Funkcia realizujúca prediktívne riadenie systému v simulačnej schéme
cebysev, hermit, laguerre, legendre	Funkcie pre ortogonálne aktivačné funkcie
modmask, regmask	Funkcie na grafické užívateľské prostredie pre modelovanie a riadenie systémov

Tabuľka 2: Popis parametrov dátovej štruktúry NSOAF

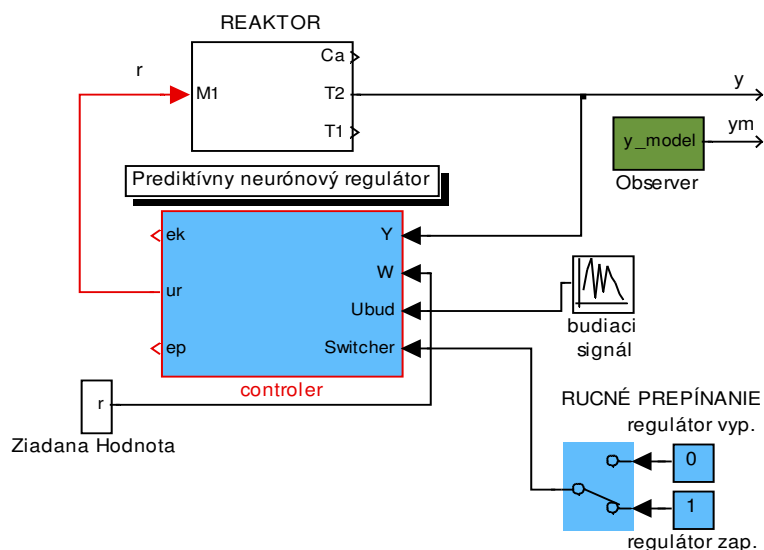
Net	Názov štruktúry
numInput	Počet všetkých vstupov
nu	Počet vstupov U
ny	Počet vstupov Y
numInputNeuron	Vektor, ktorého prvky udávajú počet neurónov v jednotlivých vstupných blokoch
Afun	Ortogonálna aktivačná funkcia
minmaxU	Vektor určujúci rozsah vstupných vzoriek
minmaxY	Vektor určujúci rozsah výstupných vzoriek
norm	Vektor koeficientov normalizácie vstupu a výstupu procesu
P0	Ak sú $\Pi$ -uzly vytvorené zo všetkých kombinácií, potom $P_0$ =počet $\Pi$ -uzlov, ak sa vytvoria iba tie $\Pi$ -uzly, ktoré vyhovujú podmienke rád $\Pi$ -uzla < max. rád, potom $P_0$ =max. rád
W	Váhy jednotlivých $\Pi$ -uzlov
Adapt	Štruktúra obsahujúca informácie o adaptačnom mechanizme siete
Regulator	Štruktúra obsahujúca informácie o parametroch regulácie

## 6 Modelovanie a riadenie chemického reaktora pomocou NSOAF v prostredí Matlab/Simulink.

V kontinuálnom reaktore (obr. 4) prebieha exotermická reakcia (vzniká teplo), ktorá má oddeliť vstupnú zmes od látky A. Reakcia je riadená teplotou akčnej zmesi  $T_2$  (výstupná veličina z hľadiska riadenia). Riadiacou veličinou je prietok chladiaceho média (vody) plášťom reaktora  $M_1$ . Prebiehajúca reakcia je nelineárna 1. rádu.[2, 8]



Obrázok 4: Model chemického kontinuálneho reaktora



Obrázok 5: Zapojenie simulačnej schémy reaktora s prediktívnym neurónovým regulátorom

Pre chemický reaktor bolo navrhnuté prediktívne riadenie, ktoré bolo realizované pomocou algoritmov opísaných v literatúre [2, 4] vo funkcii *controlNNOAF*. Parametre NSOAF modelu a regulátora použité na dosiahnutie daných výsledkov riadenia sú uvedené v Tabuľke.3 a na obrázku 6, kde je možné vidieť grafické užívateľské prostredie bloku prediktívneho neurónového regulátora v simulačnej schéme na obrázku 5.

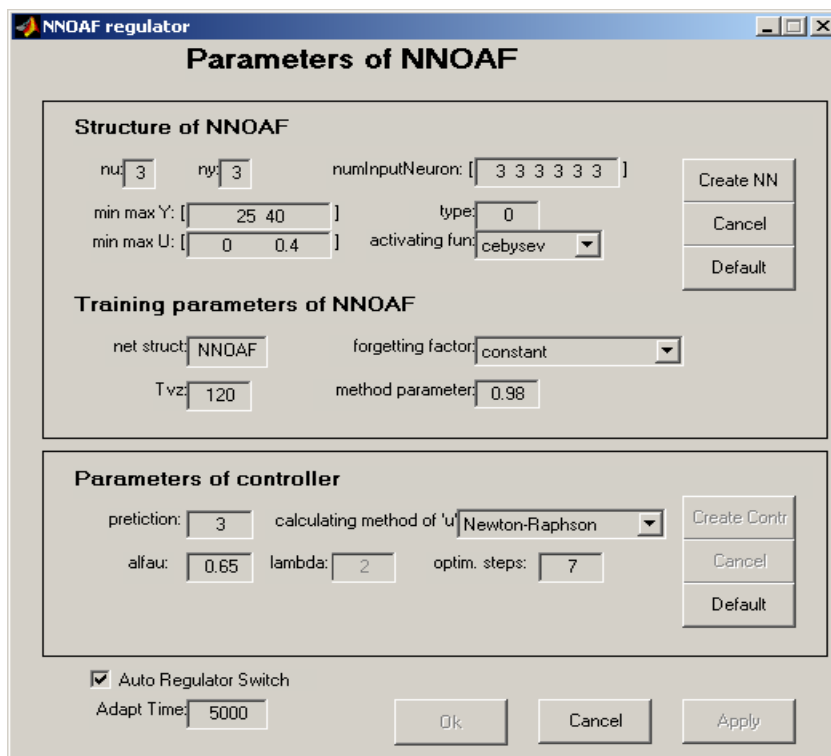
Tabuľka 3: Parametre NSOAF modelu a prediktívneho regulátora

nu=3	Počet oneskorení vstupu U
ny=3	Počet oneskorení vstupu Y
numInputNeuron=[3,3,3,3,3,3]	Počet neurónov vo vstupných blokoch (rády akt. funkcií)
minmaxU=[0,0.4]	Rozsah vstupu
minmaxY=[25,40]	Rozsah výstupu
Type=0	Len $\Pi$ -uzly, kt. rád je $\leq$ max rád
Aktivacion fnc. = „cebyšev“	Typ aktivačnej funkcie
Prediction =3	Počet krokov predikcie
Optim. Steps =7	Počet optimalizačných krokov
Calculating meth. =Newton-Raphson	Metóda optimalizácie „u“


Pre nastavené parametre prediktívneho neurónového regulátora bola realizovaná simulácia veličín procesu pre skokové zmeny žiadanej hodnoty. Na obrázku.7 sú zobrazené časové priebehy výstupu regulovaného procesu a referenčného signálu. Čas zapnutia regulátora je vyznačený červenou čiarou. V časovom úseku pred týmto prepnutím prepínača prebiehalo tréningovanie neurónového modelu procesu náhodným tréningovacím signálom, proces optimalizácie riadiaceho zásahu bol zatiaľ vypnutý (blok budiaci signál na obr. 5).

Časový priebeh riadiaceho zásahu regulátora (prietok  $M_I$ ) je zobrazený na obr. 7a). Na grafe je farebne odlíšený budiaci signál, ktorý je použitý na počiatkové natréningovanie siete do času 5000s. Priebeh regulačnej odchýlky je na obr. 7b). Výstup NSOAF modelu počas simulácie (výstup z vyššie opísaného bloku *Observer*: (Obr.5) je porovnaný s výstupom z procesu na Obr. 8.


Na prediktívnom riadení chemického reaktora bola demonštrovaná schopnosť využitia navrhnutých štruktúr a prostriedkov NSOAF na riadenie a modelovanie uvedeného dynamického systému. Dosiahnuté výsledky potvrdzujú veľmi dobrú kvalitu modelovacích a riadiacich schopností navrhovaných algoritmov. Prípadnú inú dynamiku výsledného procesu riadenia by sme docielili vhodnými zmenami parametrov regulátora.




Obrázok 6: Nastavenie parametrov NSOAF modelu a prediktívneho regulátora



Obrázok 7: Časové priebehy výstupu regulovaného procesu a referenčnej veličiny



Obrázok 8: Časové priebehy a) radiaceho zásahu, b) regulačnej odchyľky





Obrázok 9: Časové priebehy výstupov NSOAF modelu a procesu



## 7 Modelovanie jednosmerného motora pomocou NSOAF v reálnom čase

Modelovanie dynamických systémov pomocou NSOAF bolo testované v simulačnom prostredí Matlab/Simulink využitím blokov Real Time Toolboxu.[7]. On-line modelovanie sme testovali na laboratórnom modeli jednosmerného motora (obr. 10). Jeho vstupom je riadiace napätie (veľičina  $U_{in}$ ) v rozsahu 0 až 10V. Informáciu o rýchlosti otáčok motora zabezpečuje snímač rýchlosti, ktorého hodnoty sú v rozsahu 0 až 10V (veľičina  $U_{out}$ ). Parametre systému (jeho dynamiku) je možné nastaviť potenciometrom. Hodnotu tohto nastavenia sme snímali ako ďalšiu veličinu ( $U_{par}$ ). K systému sme pristupovali metódou „black box“, a preto sme sa nezaoberali jeho fyzikálnym modelom.[2, 3]

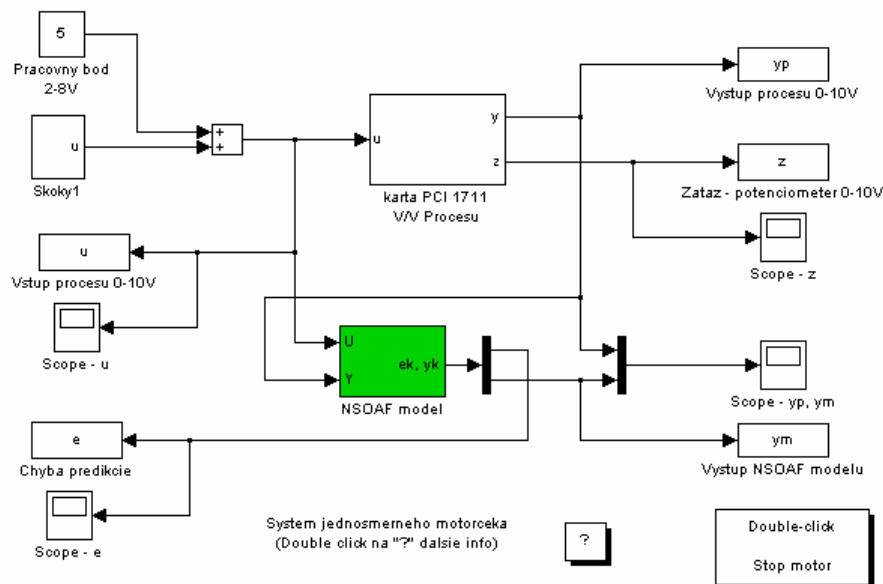


Obrázok 10: Zapojenie modelu jednosmerného motora pre modelovanie v reálnom čase

Všetky experimenty boli realizované pomocou rozhrania PC karty PCI 1711 a blokov RealTime toolboxu v simulačnej schéme na obr. 11. Merania prebiehali s periódou vzorkovania  $T_{vz}=0.1s$ . V Tab. 4 sú zobrazené a popísané parametre modelovania pomocou NSOAF adaptívneho modelu, ktoré sme zvolili pri tomto experimente.

Tabuľka 4: Parametre neurónového modelu


nu=3	Počet oneskorení vstupu U
ny=3	Počet oneskorení vstupu Y
numInputNeuron=[3,3,3,3,3,3]	Počet neurónov vo vstupných blokoch (rády akt. funkcií)
minmaxU=[0,4]	Rozsah vstupu
minmaxY=[0,10]	Rozsah výstupu
Type=0	Len II-uzly, kt. rád je $\leq$ max rád
Aktivacia fnc.= „legendre“	Typ aktivačnej funkcie



Obrázok 11: Meracia schéma modelovania jednosmerného motora pomocou NSOAF modelom

Výsledky snímania veličín počas tohto experimentu NSOAF *ON-line* modelovania sú zobrazené na obrázku 12. Počas experimentu sme náhodne menili hodnotu  $U_{par}$  pomocou potenciometru (obr. 10). Tým sme vlastne počas behu modelovania menili parametre procesu (jeho dynamiku), čím sme testovali schopnosť navrhnutého modelovacieho prostriedku adaptovať sa na takéto zmeny parametrov.

Z časových priebehov na obr. 12 je zrejmé, že vo všetkých prípadoch je kvalita modelovania veľmi dobrá. Na začiatku potrebuje systém krátky čas na to, aby sa „zadaptoval“. Po adaptácii model sleduje priebeh reálneho procesu s veľmi dobrou presnosťou.



Obrázok 12: Porovnanie výstupov z procesu a NSOAF modelu

## 8 Záver

Príspevok chcel poukázať na realizáciu modelovania a riadenia dynamických procesov pomocou NSOAF v prostredí Matlab. Z modelovania jednosmerného motora v reálnom čase sme zistili, že NSOAF má schopnosť veľmi rýchlo prispôbiť model na zmenu parametrov systému a neuronový model vykazuje pomerne malú odchýlku od procesu. Na simulačných a reálnych systémoch boli ukázané veľmi dobré modelovacie schopnosti NSOAF. NSOAF modely znižujú počet iterácií pri určovaní optimálnych nastavení váh a lepšie modelujú dynamické systémy s nelinearitami polynomiálneho a exponenciálneho charakteru. Vytvorené programy a simulačné schémy v prostredí Matlab sú pomocou NSOAF schopné riešiť nasledovné aplikácie: identifikáciu koeficientov Fourierového radu harmonického signálu, identifikáciu frekvenčnej charakteristiky procesu, off-line a on-line modelovanie nelineárnych systémov, modelovanie dynamických systémov v reálnom čase a prediktívne riadenie simulačných modelov procesov.

## Literatúra

- [1] Z. Chaozing: *Control and Dynamic System*, ACADEMIC PRESS, 1998
- [2] S. Kajan: *Modelovanie a riadenie nelineárnych systémov neuronovými sieťami s ortogonálnymi aktivačnými funkciami*, Dizertačná práca, FEI STU Bratislava, 2005
- [3] S. Kajan: *Modelovanie dynamických systémov pomocou neuronových sietí v reálnom čase*, AT&P journal Plus7 2005, Bratislava, 2005, s. 41-44
- [4] Š. Kozák: *Self-Tuning Neural Controller Design with Orthonormal Activation Functions*. Journal of Electrical Engineering, roc.50, 1999, c.11-12, s. 346-355
- [5] L. Korosi, Š. Kozák: *Improvement Properties of Neural Networks Using Orthogonal and Wavelet Functions*. Control Systems Design. Bratislava : SSCI, 2003
- [6] The Mathworks: *Matlab ver. 6.5 (R13)*, user dokumentation, 2002
- [7] The Humusoft s.r.o.: *Real Time Toolbox version 3.12*, user's manual, 2003
- [8] M. Kopál: *Neuronové siete s ortogonálnymi aktivačnými funkciami v procese riadenia dynamických systémov*. Diplomová práca, Bratislava : KASR FEI STU, 2003.

## Pod'akovanie

Príspevok bol podporený grantom VEGA č. 1/3100/06 a projektom agentúry APVV: APVT-20-031404 ("AUIKE")

---

Ing. Slavomír Kajan, PhD.:

Ústav riadenia a priemyselnej informatiky, Fakulta elektrotechniky a informatiky, Slovenská technická univerzita v Bratislave, Ilkovičova 3, 812 19 Bratislava, E-mail: slavomir.kajan@stuba.sk