

# Virtuálne senzory magnetického toku AM

Ján Jovankovič  
Milan Žalman

Článok opisuje priame vektorové riadenie asynchrónneho motora (AM) v uzavretej štruktúre, kde sa na pozorovanie zložiek vektora magnetického toku rotora používajú virtuálne senzory, založené na báze umelých neurónových sietí (UNS). Takéto pozorovatele preukazujú vysokú robustnosť voči variácii parametrov systému a dobre potláčajú šum. Virtuálny senzor vektora magnetického toku rotora sa skladá z dvoch dvojrstvových rekurentných neurónových sietí typu 4-6-1. Uzavretá rýchlostná riadiaca štruktúra bola realizovaná na vývojovom systéme dSPACE DS 1102 s 1.1 kW AM.

## 1. Úvod do problematiky

Kľúčovú úlohu vo vektorovom riadení zohráva pozorovateľ uhla natočenia vektora magnetického toku rotora. Od presnosti pozorovateľa závisí kvalita riadenia. Pre priame vektorové riadenie potrebujeme vedieť uhol natočenia vektora magnetického toku rotora vzhľadom na súradnicový systém statora (1). Pomocou vzťahu (2) sa dá vektor magnetického toku rotora  $\Psi_r$  priamo pozorovať.

$$v_s = \arctg \frac{\Psi_{r\alpha}}{\Psi_{r\beta}} \quad (1)$$

$$\Psi_r = \frac{L_m}{L_r} \left( \int \mathbf{u}_s - R_s \mathbf{i}_s dt - \sigma L_s \mathbf{i}_s \right) \quad (2)$$

Nevýhodou modelu je vysoká citlivosť na presnosť parametra odporu statora  $R_s$ , a integrovanie chyby šumu v meracom kanáli prí-

du. Invariantnosť pozorovateľa  $\Psi_r$  voči zmenám parametrov (napr.  $R_s$ ) a zašumeným signálom prúdu môžeme zabezpečiť pomocou virtuálnych snímačov na báze umelých neurónových sietí (UNS). UNS sú schopné presne aproximovať zložité zobrazenia a jednou z možností ich nasadenia v servopohonoch je pozorovanie stavových veličín pomocou vstupno-výstupného modelu. V niektorých prípadoch ide o zložité nelineárne modelovanie MIMO. Vhodný názov pre takto natrénovanú sieť je **virtuálny senzor**, pretože po naučení vstupno-výstupnej charakteristiky veličín preberá úlohu senzora v riadiacom systéme. Na ich tréning je vhodná off-line metóda učenia, pri ktorej vďaka vysokej robustnosti UNS možno použiť signály získané z experimentov na simulačných modeloch. Konkrétne použitie v riadiacom systéme tranzistorových meničov frekvencie vidíme v tvare preddefinovaných blokov zabudovaných

priamo v meničoch, ktoré budú mať funkciu snímačov magnetického toku. Ich použitie by malo zvýšiť robustnosť riadiacej štruktúry a skvalitniť styk s užívateľom.

## 2. Virtuálne senzory na báze UNS

Modelovanie toku  $\Psi_r$  pomocou doprednej štruktúry NS sťažuje integrálna charakteristika veličín. Dopredné NS totiž nedokážu namodelovať integrál. Preto sme sa rozhodli využiť rekurentnú NS typu NSOE (obr. 1) s nasledovnou funkčnou závislosťou (obr. 2):

$$\tilde{\Psi}_{r\alpha}(k+1) = f_{\alpha}(u_{s\alpha}(k), i_{s\alpha}(k), i_{s\alpha}(k-1), \tilde{\Psi}_{r\alpha}(k)) \quad (3)$$

$$\tilde{\Psi}_{r\beta}(k+1) = f_{\beta}(u_{s\beta}(k), i_{s\beta}(k), i_{s\beta}(k-1), \tilde{\Psi}_{r\beta}(k)) \quad (4)$$

pričom

$\Psi_{r\alpha}, \Psi_{r\beta}$  sú pozorované zložky vektora magnetického toku rotora v súradnicovom systéme  $[\alpha, \beta]$ ,

$u_{s\alpha}, u_{s\beta}$  sú merané zložky napätia v súradnicovom systéme  $[\alpha, \beta]$ ,

$i_{s\alpha}, i_{s\beta}$  sú merané zložky prúdu v súradnicovom systéme  $[\alpha, \beta]$ .

Pre aproximáciu každej z nich sme zvolili NS s jednou skrytou vrstvou, ktorá obsahuje 6 neurónov s aktivačnými funkciami tansig, zatiaľ čo výstupný neurón má lineárnu prenosovú funkciu. Matematický opis NS zobrazujú vzťahy (5) až (11).

prenos neurónov v skrytej vrstve

$$\tan \sin g(a) = \frac{2}{1 + \exp(-2a)} - 1 \quad (5)$$

potenciál neurónov

$$a_i = \sum_{j=1}^n w_{ij} x_j + b_i \quad (6)$$

vstupy do NS


$$\mathbf{x} = [u_{s\alpha, \beta}(k), i_{s\alpha, \beta}(k), i_{s\alpha, \beta}(k-1), \tilde{\Psi}_{r\alpha, \beta}(k)] \quad (7)$$

výstup z 1. vrstvy

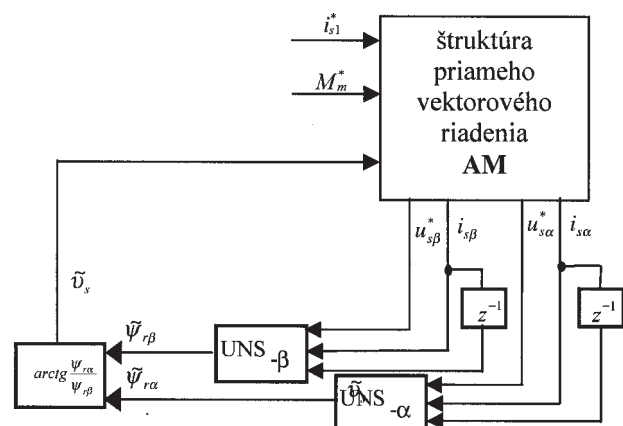
$$\mathbf{y1} = [y1_1, y1_2, \dots, y1_6] \quad (8)$$

$$\mathbf{y1} = \mathbf{F1}(\mathbf{W1x} + \mathbf{B1}) \quad (9)$$

pričom



Obr.1 Štruktúra NS typu NSOE



Obr.2 Štruktúra vektorového riadenia s virtuálnym senzorom magnetického toku

$$\mathbf{F1}(\tan \text{sig}(\mathbf{a1})) = \text{diag} \left[ f1(\tan \text{sig} a1_1), f1(\tan \text{sig} a1_2), \dots, f1(\tan \text{sig} a1_6) \right] \quad (10)$$

výstup zo siete

$$\mathbf{y2} = \mathbf{F2}(\mathbf{W2y1} + \mathbf{B2}) = \mathbf{F2}(\text{purelin}(\mathbf{a2})) \quad (11)$$

## 3. Trénovanie NS


Po výbere štruktúry NS má trénovanie najväčší vplyv na kvalitu aproximácie. V našom prípade je vhodné off-line trénovanie pomocou učiteľa, pričom reprezentatívne vzorky vstupov a želaných výstupov sme získali pomocou experimentu na simulačnom modeli rýchlostného servopohonu vektorovo riadeného AM (obr. 6). Pri trénovaní pozorovateľa sa zahrnul aj vplyv zmeny záťažového momentu.

Na obr. 3a je priebeh uhlovej rýchlosti. Priebeh želaných hodnôt je zobrazený na obr. 3b. Priebeh vstupných parametrov pre trénovanie reálnej zložky vektora magnetického toku rotora  $\Psi_{r\alpha}$  je na obr. 4a. Učenie prebiehalo off-line s cieľom minimalizovať účelovú funkciu (12). Optimalizácia prebiehala pomocou algoritmu spätnej propagácie Levenberga – Marquardta. Úprava váhových koeficientov sa realizovala pomocou vzťahu (13). Proces učenia je na obr. 4b.


$$e = \frac{1}{Q} \sum_{q=1}^Q (\Psi_{r\alpha_q}^* - \tilde{\Psi}_{r\alpha_q})^2 \quad (12)$$

$$\Delta \mathbf{W} = (\mathbf{J}^T \mathbf{J} + \mu \mathbf{I})^{-1} \mathbf{J}^T \mathbf{e} \quad (13)$$


pričom  $\mathbf{J}$  je matica Jakobian,  $\mathbf{J}^T \mathbf{J}$  je aproximovaná matica Hessian,  $\mathbf{J}^T \mathbf{e}$  je vektor gradientu,  $\mathbf{I}$  je jednotková matica a  $\mu$  je hodnota adaptácie.



Obr.3 a) prechodová charakteristika uhlovej rýchlosti pre trénovacie vzorky  $\Psi_{r\alpha}, \Psi_{r\beta}$ , b) priebeh želaných hodnôt



Obr.4 a) priebeh vstupných parametrov  $\Psi_{r\alpha}(k), u_{s\alpha}(k), i_{s\alpha}(k), i_{s\alpha}(k-1)$ , b) proces učenia pre  $f_{\alpha}$

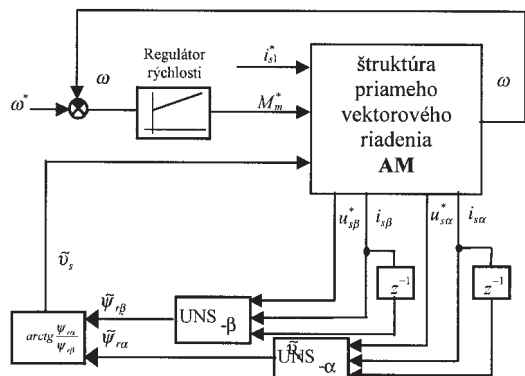


Obr.5 a) priebeh vstupných parametrov, b) proces učenia pre  $f_{\beta}$


Priebeh vstupov a tréovanie NS na imaginárnu zložku vektora magnetického toku  $\psi_{r\beta}$  je na obr. 5.

#### 4. Realizácia na vývojovom systéme dSPACE DS 1102


Rýchlostný servopohon vektorovo riadeného AM (obr. 6) sme realizovali na vývojovom systéme dSPACE DS 1102. Využili sme natréované neurónové siete na simulačnom modeli. Riadenie v reálnom čase bolo realizované pomocou karty PC ISA so signálovým procesorom TMS 320 C 31. Táto karta dokáže vygenerovať a vykonávať algoritmus priamo z riadiacej štruktúry, ktorú máme pripravenú v MATLABe [3]. Na napájanie motora bol použitý IGBT napáťový menič VS 400/7,5 -2Q. Pozorovatele sme testovali pri vyšších aj nižších uhlových rýchlostiach, skúšali sme reverzáciu a nakoniec sme vyskúšali aj vplyv skoku záťaže. Na obr. 7a je prie-




Obr.6 Rýchlostná štruktúra vektorovo riadeného AM s virtuálnym senzorom  $\psi_r$




Obr.7 a) priebeh uhlovej rýchlosti, b) priebeh pozorovaných veličín




Obr.8 a) priebeh uhlovej rýchlosti, b) priebeh pozorovaných veličín



Obr.9 a) priebeh uhlovej rýchlosti, b) priebeh pozorovaných veličín



Obr.10 a) priebeh uhlovej rýchlosti, b) priebeh momentu



Obr.11 Priebeh zložiek vektora magnetického toku rotora

beh uhlovej rýchlosti pre želanú rýchlosť 50 rad/s. Priebeh pozorovaných veličín virtuálneho pozorovateľa vektora magnetického toku v komplexnej rovine je na obr. 7b. Výsledky testovania pre žiadanú uhlovú rýchlosť 5 rad/s zobrazuje obr. 8.

Priebeh uhlovej rýchlosti pri reverzácii z 20 na -20 rad/s a priebeh pozorovaných veličín zobrazuje obr. 9.

Vplyv skoku záťaže v hodnote 2 Nm, pri rýchlosti 40 rad/s zobrazujú obr. 10 a 11.

#### Záver

Pozorovanie reálnej a imaginárnej zložky vektora magnetického toku rotora pomocou UNS predstavuje nesmierne zložitý problém. Neurónová sieť musí dokázať pozorovať harmonické signály, ktoré v čase môžu meniť frekvenciu a fázu. Problém sa skomplikoval zavedením rekurentnej NS, čím sme získali model, citlivejší na výstupnú nepresnosť (chyba sa okamžite prenáša na vstup NS).

Príspevok poukazuje na možnosti aplikácie neurónových sietí vo funkcii virtuálnych senzorov v tvare preddefinovaných blokov, zabudovaných priamo v meničoch frekvencie. Učenie NS vďaka ich vysokej robustnosti dokážeme realizovať experimentmi na simulačných modeloch. Ako poukazujú realizované experimenty, aplikácia virtuálnych senzorov zvyšuje robustnosť rýchlostného servopohonu a skvalitňuje styk s používateľom.

#### Literatúra

- [1] VAS, P.: Artificial-Intelligence-Based Electrical Machines and Drives. Oxford University Press, 1999.
- [2] JOVANKOVIČ, J., ŽALMAN, M., BÉLAI, I.: Neural Network Estimation of the Rotor Speed for Direct Field Oriented Control. EPE-PEMC '2000 Košice.
- [3] dSPACE: Real-Time Interface – Implementation Guide. Version 1.2, dSPACE 1999.
- [4] ŽALMAN, M., JOVANKOVIČ, J.: Dynamické riadenie AM pomocou virtuálnych snímačov. Konferencia Kybernetika a informatika. Trebišov 2002.

prof. Ing. Milan Žalman, PhD.  
Ing. Ján Jovankovič

Slovenská technická univerzita  
Fakulta elektrotechniky a informatiky  
Ilkovičova 3, 812 19 Bratislava  
e-mail: zalman,jovankovic@nov1.kar.elf.stuba.sk