

Aplikácia neurónových sietí v otvorenom rýchlostnom servopohone s asynchrónnym motorom

Milan Žalman
Ján Jovankovič

Jednou z možností, ako úspešne aplikovať umelú inteligenciu vo frekvenčných meničoch, je pozorovanie stavových veličín servopohonu pomocou umelých neurónových sietí (UNS), ktoré sú schopné presne aproximovať zložité nelineárne funkcie. Neurónové siete natrénované na pozorovanie stavových veličín sa nazývajú virtuálnymi senzormi, pretože po svojom natrénovaní na vstupno-výstupnú funkciu preberajú v riadiacom obvode úlohu senzorov. V článku je opísaná aplikácia UNS v rýchlostnej bezsenzorovej (sensorless) štruktúre vektorového riadenia s asynchrónnym motorom (AM). Sú rozpracované dve štruktúry pozorovania uhlovej rýchlosti pomocou dopredných neurónových sietí s jednou skrytou vrstvou. Štruktúra, ktorá na pozorovanie používa merané hodnoty statorových prúdov a napätí, má dobré vlastnosti v nízkych rýchlostiach. Oproti tomu štruktúra, ktorá na pozorovanie používa hodnoty prúdov a napätí v súradnicovom systéme magnetického toku rotora, má lepšie vlastnosti pre stredné a vyššie hodnoty uhlovej rýchlosti. Obidve štruktúry boli zrealizované na vývojovom systéme dSPACE DS 1102 s 1,1 kW AM. Virtuálne senzory uhlovej rýchlosti prinášajú vyššiu kvalitu bezsenzorových štruktúr s AM, sú menej citlivé na zmeny parametrov a robustné na vplyv poruchy.

Úvod

V súčasnosti vznikli trhové požiadavky na vývoj bezsenzorových rýchlostných servopohonov s AM pre dynamické aplikácie, ktoré by boli menej náročné na presnosť (navíjačky, žeriavy), čím by sa ušetrili náklady na drahé snímače polohy, resp. rýchlosti. V takýchto systémoch sa uhlová rýchlosť nemeria priamo, ale vyhodnocuje sa pomocou meraných elektrických veličín (napätie, prúd). Niekoľko štruktúr založených na MRAS je dôkladne rozpracovaných v [1], [2], [3]. Vo všetkých štruktúrach MRAS sú referenčné modely veľmi citlivé na presnú parametrickú identifikáciu systému frekvenčný menič – asynchrónny motor. Hodnoty niektorých parametrov AM (odpor statora, odpor rotora) sa počas prevádzky môžu výrazne meniť a pri aplikácii jednotlivých štruktúr MRAS sa musí zabezpečiť aj on-line identifikácia parametrov [4], [5]. Aj napriek tomu sú tieto štruktúry problematické pri veľmi nízkych alebo vysokých hodnotách uhlovej rýchlosti. S rastom počítačovej výkonnosti sa objavili aj pokusy aplikovania virtuálnych senzorov uhlovej rýchlosti založených na UNS [6], [7]. Riadiace bezsenzorové štruktúry s virtuálnymi senzormi (VS) majú niekoľko výhod:

- štruktúry s VS v späťnej väzbe sú robustné voči parametrickým zmenám stavových veličín,
- umožňujú off-line tréning na simulačných modeloch (je možný výber najlepšej aproximácie),
- jednoduchší a kvalitný styk s používateľom a
- možnosť vytvoriť knižnicu virtuálnych senzorov ako súčasť frekvenčného meniča pre presne stanovený typ motora a pozorované stavové veličiny.

Pri návrhu virtuálnych senzorov je veľmi dôležitý výber vstupno-výstupnej relácie, ktorá sa bude pomocou UNS aproximovať. Kvalitu aproximácie ovplyvňuje aj voľba tréningovej množiny. Veľmi často je výber relácie a tréningovej množiny podložený iba expertnou znalosťou procesu. V článku sú rozpracované dve štruktúry virtuálnych senzorov (VS) uhlovej rýchlosti založených na doprednej neurónovej sieti (DNS) s jednou skrytou vrstvou. Vstupné veličiny pre prvú štruktúru sú merané hodnoty statorových prúdov a napätí, zatiaľ čo druhá používa hodnoty prúdov a napätí v súradnicovom systéme magnetického toku rotora. Obidve štruktúry boli realizované na vývojovom systéme dSPACE DS 1102 s 1,1 kW AM.

1. Virtuálny senzor rýchlosti v súradnicovom systéme (α, β)

Základná štruktúra UNS pozorovateľa [6] aproximuje uhlovú rýchlosť pomocou nasledovnej relácie:

$$\tilde{\omega}(k+1) = f_{[\alpha,\beta]} \left\{ i_{[\alpha,\beta]}(k), i_{[\alpha,\beta]}(k-1), i_{[\alpha,\beta]}(k-m), u_{s[\alpha,\beta]}(k), u_{s[\alpha,\beta]}(k-1), u_{s[\alpha,\beta]}(k-n) \right\}$$

kde $\tilde{\omega}(k+1)$ je pozorovaná uhlová rýchlosť,

$i_{s\alpha}(k)$ – reálna zložka vektora statorového prúdu v súradnicovom systéme statora (α, β) ,

$i_{s\beta}(k)$ – imaginárna zložka vektora statorového prúdu v (α, β) ,

$u_{s\alpha}(k)$ – reálna zložka vektora napätia statora v (α, β) ,

$u_{s\beta}(k)$ – imaginárna zložka vektora napätia statora v (α, β) .

Zložky vektora prúdu a napätia v súradnicovom systéme (α, β) sú harmonické vstupné signály s premenlivou frekvenciou, ktorá sa prenáša na výstup a spôsobuje kmitanie pozorovanej uhlovej rýchlosti. Preto sme sa rozhodli použiť funkčne upravené zložky prúdových a napäťových signálov (1).

$$\tilde{\omega}(k+1) = f_{(\alpha,\beta)} \{ X_N(k), X_M(k), X_M(k-1) \} \quad (1)$$

kde

$$X_N = i_{s\alpha}(k)u_{s\alpha}(k) + i_{s\beta}(k)u_{s\beta}(k)$$

$$X_M = i_{s\alpha}(k)u_{s\beta}(k) - i_{s\beta}(k)u_{s\alpha}(k)$$


Na aproximáciu relácie (1) bola použitá dvojvrstvomá dopredná neurónová sieť so šiestimi neurónmi v skrytej vrstve, ktoré majú tangis nelineárne aktivačné funkcie (2). Výstupný neurón má lineárnu aktivačnú funkciu. UNS môžeme opísať pomocou nasledovných vzťahov (2 - 8):

aktivačná funkcia neurónov v skrytej vrstve


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

potenciál neurónu

$$a_i = \sum_{j=1}^n w_{ij}x_j + b_i \quad (3)$$



Obr.1 Trénovacia množina pre VS (α, β)
a) vstupy b) želané výstupy



Obr.2 Proces učenia VS (α, β)

vstupný vektor

$$\mathbf{x}(k) = [X_N(k), X_M(k), X_M(k-1)] \quad (4)$$

výstup z prvej vrstvy

$$\mathbf{y}_1 = [y_{11}, y_{12}, \dots, y_{16}] \quad (5)$$

$$\mathbf{y}_1 = \mathbf{F}_1(\mathbf{W}_1 \mathbf{x} + \mathbf{B}_1) \quad (6)$$

kde

$$\mathbf{F}_1(\tan \text{sig}(\mathbf{a}_1)) = \text{diag} \left[\begin{matrix} f_1(\tan \text{sig} a_{11}), f_1(\tan \text{sig} a_{12}), \\ \dots, f_1(\tan \text{sig} a_{16}) \end{matrix} \right] \quad (7)$$

výstup

$$\mathbf{y}_2 = \mathbf{F}_2(\mathbf{W}_2 \mathbf{y}_1 + \mathbf{B}_2) = \mathbf{F}_2(\text{purelin}(\mathbf{a}_2)) \quad (8)$$

2. Virtuálny senzor rýchlosti v súradnicovom systéme (1, 2)

Iná možnosť pozorovania uhlovej rýchlosti pomocou UNS je aproximácia relácie (9), kde vstupnými premennými sú hodnoty prúdov a napätí v súradnicovom systéme magnetického toku rotora [7]. Potom reláciu uhlovej rýchlosti od vstupných veličín môžeme vyjadriť ako:

$$\tilde{\omega}(k+1) = f_{(1,2)}[i_{s2}(k), i_{s2}(k-1), u_{s2}^*(k), u_{s2}^*(k-1)] \quad (9)$$


kde $i_{s2}(k)$ je momentotvorná zložka prúdu v súradnicovom systéme magnetického toku rotora (1, 2),

$u_{s2}(k)$ je imaginárna zložka vektora napätia v súradnicovom systéme (1, 2).


Na aproximáciu relácie (9) bola znovu použitá dvojvrstváva dopredná neurónová sieť so šiestimi neurónmi v skrytej vrstve. Matematický model UNS je veľmi podobný modelu (2 – 8).

3. Proces učenia

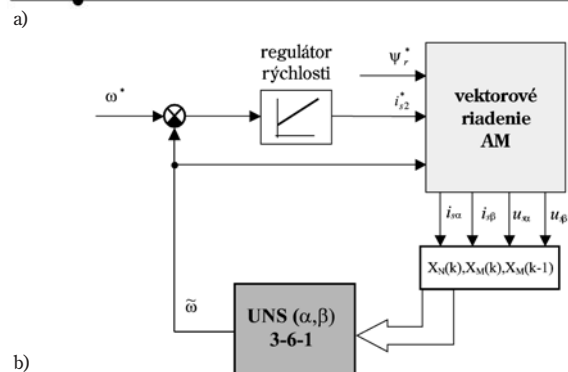
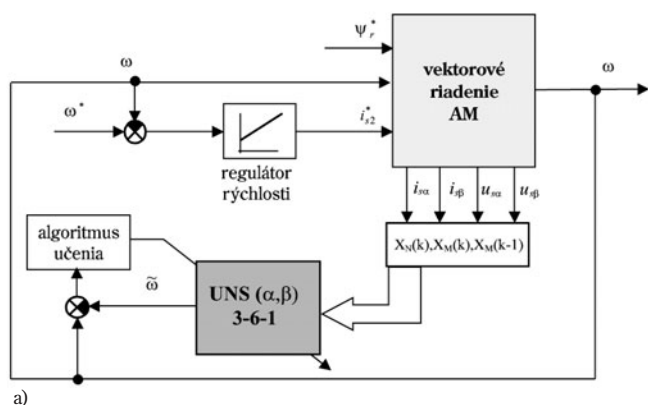
Trénovanie neurónových sietí prebiehalo off-line v simulačnom modeli rýchlostnej štruktúry vektorového riadenia (obr. 5a) a (obr. 8a). Úprava váh v neurónových sieťach bola zabezpečená pomocou spätnej propagácie metódou Levenberga-Marquardt. Cieľom optimalizácie bola minimalizácia účelovej funkcie (10).




Obr.3 Trénovacia množina pre VS (1, 2)
a) vstupy b) želané výstupy




Obr.4 Proces učenia VS (α, β)



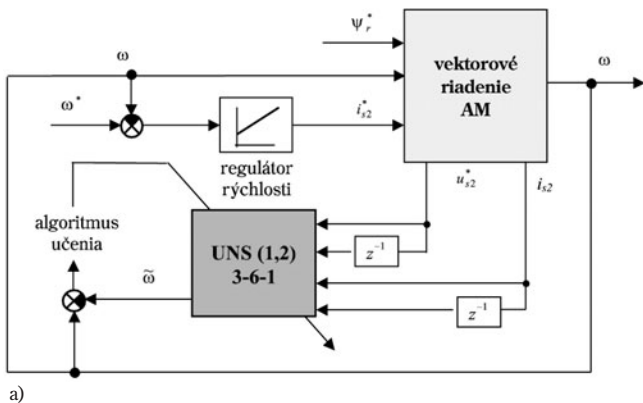
Obr.5 a) blokova schéma na získanie trénovacej množiny,
b) vektorové riadenie AM s VS (α, β)



Obr.6 Prechodová charakteristika pozorovanej z VS (α, β) a meranej uhlovej rýchlosti



Obr. 7 Vplyv skoku záťažového momentu na VS (α, β)



Obr. 8 a) bloková schéma na získanie tréningovej množiny, b) vektorové riadenie AM s VS (1, 2)

$$e = \frac{1}{Q} \sum_{q=1}^Q (\omega_q^* - \tilde{\omega}_q)^2 \quad (10)$$

kde Q je počet vzoriek,
 ω_q^* – q . žiadaná hodnota uhlovej rýchlosti a
 $\tilde{\omega}_q$ – aktuálna q . hodnota z UNS.

Úprava váh (w) prebieha pomocou nasledovného vzťahu:

$$\Delta W = (J^T J + \mu I)^{-1} J^T e \quad (11)$$


kde J je matrica Jacobian,
 $J^T J$ – aproximovaná matrica Hessian,
 $J^T e$ – gradientový vektor,
 I – jednotková matrica a μ je rýchlosť adaptácie.

Na obr. 2 je proces učenia pomocou spätnej propagácie Levenberga-Marquardta pre virtuálny senzor (α, β). Normovaná tréningová vstupno-výstupná množina je na obr. 1.


Na obr. 4 je zobrazený proces učenia pomocou spätnej propagácie Levenberga-Marquardta pre virtuálny senzor (1, 2). Normovaná tréningová vstupno-výstupná množina je na obr. 3.

4. Realizácia

Riadenie v reálnom čase (blokovaná schéma na obr. 5b a obr. 8b) bolo zrealizované na vývojovom systéme dSPACE DS 1102 s 1,1 kW AM pomocou internej PC ISA karty so signálovým procesorom TMS 320C 31. Meraná uhlová rýchlosť bola použitá iba na porovnanie a kvalitatívne zhodnotenie VS. Aby algoritmus riadenia na



Obr. 9 Prechodová charakteristika pozorovanej z VS (1,2) a meranej uhlovej rýchlosti



Obr. 10 Vplyv skoku záťažového momentu na VS (1, 2)

vývojovom systéme nebol preťažený, musela byť zvolená pomerne vysoká perióda vzorkovania ($T = 0,9$ ms).

4.1 Virtuálny senzor rýchlosti v súradnicovom systéme (α, β)


Na obr. 6 sú priebehy experimentov pozorovania uhlovej rýchlosti pomocou VS pre skokové zmeny žiadanej hodnoty: (a) reverzácia uhlovej rýchlosti z +5 na -5 rad/s, b) reverzácia z +25 na -25 rad/s). Vplyv skoku záťažového momentu na riadenie rýchlosti v hodnote 4 Nm počas želanej hodnoty uhlovej rýchlosti 50 rad/s zobrazuje obr. 7. V rozsahu $< -90, 90 >$ rad/s je uzavretá štruktúra s VS v spätnej väzbe stabilná a neurónová sieť má dobrú schopnosť generalizácie. Skok záťažového momentu spôsobí statickú nepresnosť pozorovania (5 %). Pomerne vysoká zvolená perióda vzorkovania spôsobí pre vyššie hodnoty uhlovej rýchlosti nepresnosť vstupných veličín, čo má za následok nestabilitu celého rýchlostného systému.

4.2 Virtuálny senzor rýchlosti v súradnicovom systéme (1, 2)

Na obr. 9 sú priebehy experimentov pozorovania uhlovej rýchlosti pomocou VS pre skokové zmeny žiadanej hodnoty (reverzácia uhlovej rýchlosti zo +170 na -70 rad/s). Vplyv skoku záťažového momentu na riadenie rýchlosti v hodnote 5 Nm počas želanej hodnoty uhlovej rýchlosti 100 rad/s zobrazuje obr. 10. Rýchlostná štruktúra s VS v spätnej väzbe má dobrú dynamickú a statickú presnosť. Pozorovaná uhlová rýchlosť je trochu kmitavá, ale kmity sa neprenášajú na skutočnú mechanickú rýchlosť. Táto štruktúra nemá požiadavku na vysokú frekvenciu vzorkovania. Nevýhoda štruktúry sa prejaví pri pozorovaní nízkych hodnôt uhlovej rýchlosti, kde dochádza k nepríjemnému dvojitému preväzbeniu stavovej veličiny i_{s2} a pozorovanej uhlovej rýchlosti. Veličina i_{s2} sa počíta pomocou transformácie, ktorá využíva uhol natočenia vektora magnetického toku rotora. Tento uhol je získaný z modelu, ktorý využíva pozorovanú uhlovú rýchlosť. Z druhej strany sa uhlová rýchlosť pozoruje pomocou veličiny i_{s2} , ktorá je vstupom do neurónovej siete. Tak sa aj malá chyba v pozorovaní v nasledovnom kroku okamžite prenesie na vstup do neurónovej siete.

Záver

Uvedený článok sa zaoberá aktuálnym trendom pozorovania uhlovej rýchlosti pomocou virtuálnych senzorov s využitím prostried-



Obr.11 Prepínací modul

kov umelej inteligencie. Predpokladali sme, že v aplikovanom otvorenom rýchlostnom systéme s AM nebude možné merať uhlovú rýchlosť. Z tohto dôvodu boli na učenie neurónových sietí použité simulačné tréningové vstupno-výstupné dáta. Predpokladáme, že výsledky by mohli byť lepšie v prípade, ak počas učenia použijeme vstupno-výstupné signály z reálneho zariadenia. Takáto aproximácia by v sebe obsahovala aj informáciu o prípadnej nelinearite výstupného signálu frekvenčného meniča. Z uvedených aplikačných príkladoch je pravdepodobnosť úspešného použitia oboch štruktúr pozorovania v prepínacom mode (obr. 11). Pre nízke rýchlosti by sa používala štruktúra virtuálneho senzora v súradnicovom systéme (α, β) a pre stredné a vyššie rýchlosti by sa štruktúra prepla na virtuálny senzor (1, 2).

Literatúra

- [1] SCHAUDER, C.: Adaptive Speed Identification for Vector Control of Induction Motors without Rotational Transducers. In IEEE Trans. on Ind. Appl., Sept./Oct., 1992, vol. 28, no. 5, pp: 1054 – 1061.
- [2] PERNG, S.-S., LAI, Y.-S., LIU, C.-H.: A Novel Sensorless Controller for Induction Motor Drives. In: EPE '97. Trondheim 1997, no. 0, pp: 4480 – 4485.
- [3] OUALHA, A., BENMESSAOUD, M., SLAMA-BELKHODJA, I., SELAMI, F.: Discrete Speed Sensorless Drive of IM: Structure and Stability. In: EPE '99. Lausanne 1999.
- [4] PENG, F.-Z., FUKAO, T.: Robust Speed Identification for Speed-Sensorless Vector Control of Induction Motors. In: IEEE Trans. on Ind. Appl., Sept./Oct., 1994, vol. 30, no. 5, pp: 123 – 124.
- [5] TUNGPIMOLRUT, K., PENG, F.-Z., FUKAO, T.: Robust Vector Control of Induction Motor without Using Stator and Rotor Circuit Time Constants. In: IEEE Trans. on Ind. Appl., Sept./Oct., 1994, vol. 30, no. 5, pp: 1241 – 1246.
- [6] VAS, P.: Artificial-Intelligence-Based Electrical Machines and Drives. Oxford University Press, Inc., New York 1999.
- [7] JOVANKOVIČ, J., ŽALMAN, M., ABELOVSKÝ, M.: Estimation of the Rotor Speed Using Feed-Forward Neural Network. International Conference on EDPE, Podbalské 2001.
- [8] JOVANKOVIČ, J., ŽALMAN, M., BÉLAI, I.: Neural Networks Estimation of the Rotor Speed for Direct Field Oriented Control. In: Proceedings. Vol. 6 of 7. EPE-PEMC 2000 Košice.

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

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

43