

Simulácia neurónového pozorovateľa rýchlosti pomocou real-time systému

Príspevok sa zaoberá návrhom neurónového pozorovateľa rýchlosti pre vektorové riadenie asynchrónneho motora. Návrh neurónového pozorovateľa bol vypracovaný v programe MATLAB-Simulink na základe jednoducho merateľných veličín, ako sú zložky statorového prúdu a napätia. Následne prebehla verifikácia neurónového pozorovateľa pomocou real-time simulácie v sústave so striedavým meničom a asynchrónnym motorom.

Klasické riešenie regulačných problémov elektrických pohonov vychádza zo znalosti matematického modelu sústavy. Pri lineárnych časovo premenných sústavách môže byť ich model natoľko zložitý, že algoritmus riadenia vychádzajúci z toho modelu nie je riešiteľný v reálnom čase. Naproti tomu riadenie na báze teórie fuzzy množín a umelých neurónových sietí nevyžaduje znalosť matematického modelu regulovanej sústavy. Hlavným znakom týchto spôsobov riadenia je schopnosť adaptácie a učenia, využitím čoho sa riadenie skvalitňuje. Moderné aplikácie umelej inteligencie v elektrických pohonoch založené na použití fuzzy logiky alebo teórie neurónových sietí pracujú vo funkcii pozorovateľov stavových veličín pre bezsnímačové regulované pohony, alebo ako regulátory rýchlosti a polohy. Vo všeobecnosti aplikácie umelej inteligencie v elektrických pohonoch môžu viesť k zlepšeniu parametrov sústavy a zvýšeniu odolnosti proti zmenám záťaže.

Bezsnímačové vektorové riadenie a modernému riadeniu na báze neurónových sietí sa v poslednom čase venuje veľká pozornosť. Bezsnímačové riadenie eliminuje potrebu senzorov rýchlosti, toku a momentu a nahradzuje ich približným výpočtom na báze digitálneho signálového procesora z okamžitých hodnôt statorových napätí a prúdov použitím modelu asynchrónneho motora. V praxi sa najčastejšie používa MRAS (Model Reference Adaptive System) štruktúra pozorovania uhlovej rýchlosti, alebo pozorovateľa založené na Kalmanovom filtri. V poslednom období sa výskumná činnosť zameriava na použitie neurónových sietí v riadení nelineárnych funkcií so želaným stupňom presnosti. Predpokladá sa, že v budúcnosti bude viac funkcií integrovaných v jednej neurónovej sieti a napokon jedna alebo dve neurónové aplikácie – špecifické čipy s integrovanými obvody – budú schopné pokryť celé riadenie elektrického pohonu.

Neurónová sieť na pozorovanie uhlovej rýchlosti

Na korektné riadenie rýchlosti asynchrónneho motora potrebujeme poznať skutočnú hodnotu rýchlosti. Túto informáciu môžeme získať na základe priameho merania rýchlosti pomocou snímača, alebo z pozorovateľa rýchlosti, ktorý zvyčajne pracuje na princípe matematického modelu asynchrónneho motora. V našom prípade sme sa rozhodli využiť umelé neurónové siete na pozorovanie rýchlosti asynchrónneho motora, pričom pri návrhu sme vychádzali z jednoducho merateľných veličín: statorového prúdu a napätia.

Vo všeobecnosti pozostáva návrh neurónového pozorovateľa z niekoľkých krokov:

- výber a príprava učiacich vzoriek,
- voľba konfigurácie a zostavenie neurónovej siete,
- učenie neurónovej siete,
- testovanie neurónovej siete.

Učiacie vzorky

Uhlová rýchlosť asynchrónneho motora je závislá od napájacieho napätia a ovplyvňuje ju záťažový moment. Preto sa za vstupné vzorky P_m na učenie neurónovej siete vybrali hodnoty statorového napätia v krokoch (k) a $(k-1)$ – $u(k)$, $u(k-1)$ a hodnoty zložiek prúdu d , q v kroku (k) a $(k-1)$ – $i_d(k)$, $i_q(k)$, $i_d(k-1)$, $i_q(k-1)$. Výstupné vzorky T_m na učenie siete predstavuje hodnota rýchlosti v kroku (k) – $\omega(k)$.

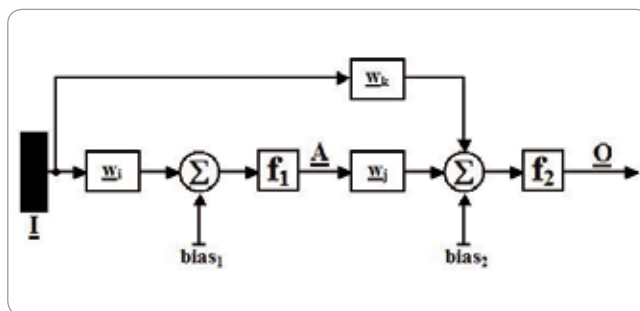
Výstupné vzorky na učenie boli reprezentované vektorom s veľkosťou $6 \times 126 \times 013$ vzoriek. Tieto vzorky boli následne normované, aby výsledná hodnota danej veličiny bola z intervalu $\langle -1, 1 \rangle$.

Konfigurácia neurónovej siete

Za neurónový pozorovateľ rýchlosti asynchrónneho motora sa zvolil kaskádový typ siete newfc s jednou skrytou vrstvou so šiestimi neurónmi, konfigurácia 6-6-1. Ako prenosové funkcie sa použili pre skrytú vrstvu nelineárna tansigmoidálna funkcia tansig a pre výstupnú vrstvu lineárna funkcia purelin. Matematicky môžeme túto neurónovú sieť opísať rovnicou:

$$\hat{\omega}(k) = \text{purelin} \left(\begin{matrix} u(k) \\ u(k-1) \\ i_d(k) \\ i_d(k-1) \\ i_q(k) \\ i_q(k-1) \end{matrix} w_p + \text{tansig} \left(\begin{matrix} u(k) \\ u(k-1) \\ i_d(k) \\ i_d(k-1) \\ i_q(k) \\ i_q(k-1) \end{matrix} w_r + \text{bias1} \right) w_s + \text{bias2} \right) \quad (1)$$

Off-line učenie neurónových sietí prebiehalo na učiacich vzorkách pomocou Levenbergovho-Marquartovho učiaceho algoritmu založeného na spätnom šírení chyby. Na obr. 1 je zobrazená principiálna schéma neurónovej siete pozorovateľa rýchlosti.



Obr. 1 Principiálna schéma neurónového pozorovateľa rýchlosti

Na tomto obrázku Q predstavuje výstupný vektor, I vektor vstupných hodnôt a w_p , w_r , w_s sú váhy prepojení jednotlivých neurónov.

$$A = f_1 \left[\sum L w_i + \text{bias}_1 \right]$$

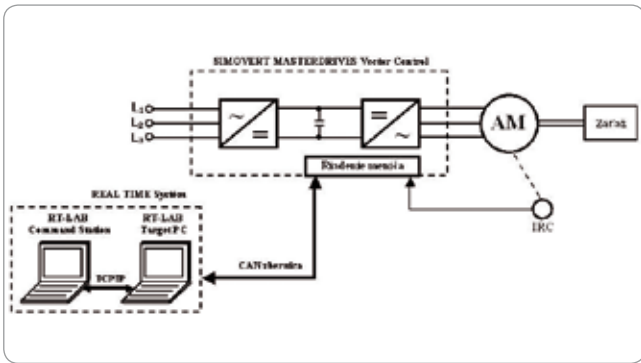
$$Q = f_2 \left[\sum (A w_j + L w_k) + \text{bias}_2 \right] \quad (2)$$

Real-time simulácia neurónového pozorovateľa rýchlosti

Na overenie navrhnutého neurónového pozorovateľa rýchlosti sa použil systém zobrazený na obr. 2. Tento reálny systém pozostával z frekvenčného meniča SIMOVERT MASTERDRIVES Vector Control, trojfázového asynchrónneho motora, inkrementálneho snímača, počítača s nainštalovaným programom MATLAB a počítača s real-time systémom.

Dosiahnuté výsledky

Verifikácia neurónového pozorovateľa rýchlosti prebiehala na real-time systéme v dvoch fázach. V prvej sa priebehy uhlovej rýchlosti dosiahnuté pozorovaním neurónovým pozorovateľom konfrontovali




Obr. 2 Principiálna schéma reálneho systému

so skutočným priebehom rýchlosti asynchrónneho motora na základe zmeny žiadanej hodnoty uhlovej rýchlosti a záťaže.


Na obr. 3 je zobrazený priebeh pozorovanej a skutočnej rýchlosti so záťažou, pričom požiadavky na zmeny rýchlostí boli rovnaké ako na predchádzajúcom obrázku. Priebeh skutočných otáčok je zobrazený červenou prerušovanou čiarou a priebeh otáčok získaný z neurónového pozorovateľa modrou plnou čiarou.

V čase 1 s bola pri nulovej záťaži zadaná zmena rýchlosti z 0 ot./min. na 5 % nominálnych otáčok, v čase 2 s na 50 % nominálnych otáčok, v čase 3 s na 100 % nominálnych otáčok a v čase 4 s bola zadaná požiadavka na reverzáciu z hodnoty 100 % nominálnych otáčok na -100 % nominálnych otáčok.



Obr. 3 Porovnanie pozorovanej a skutočnej hodnoty otáčok so záťažou

V druhej fáze sa podľa schémy uvedenej na obr. 4 informácia o otáčkach získavaná pomocou inkrementálneho snímača nahradila informáciou z neurónového pozorovateľa.



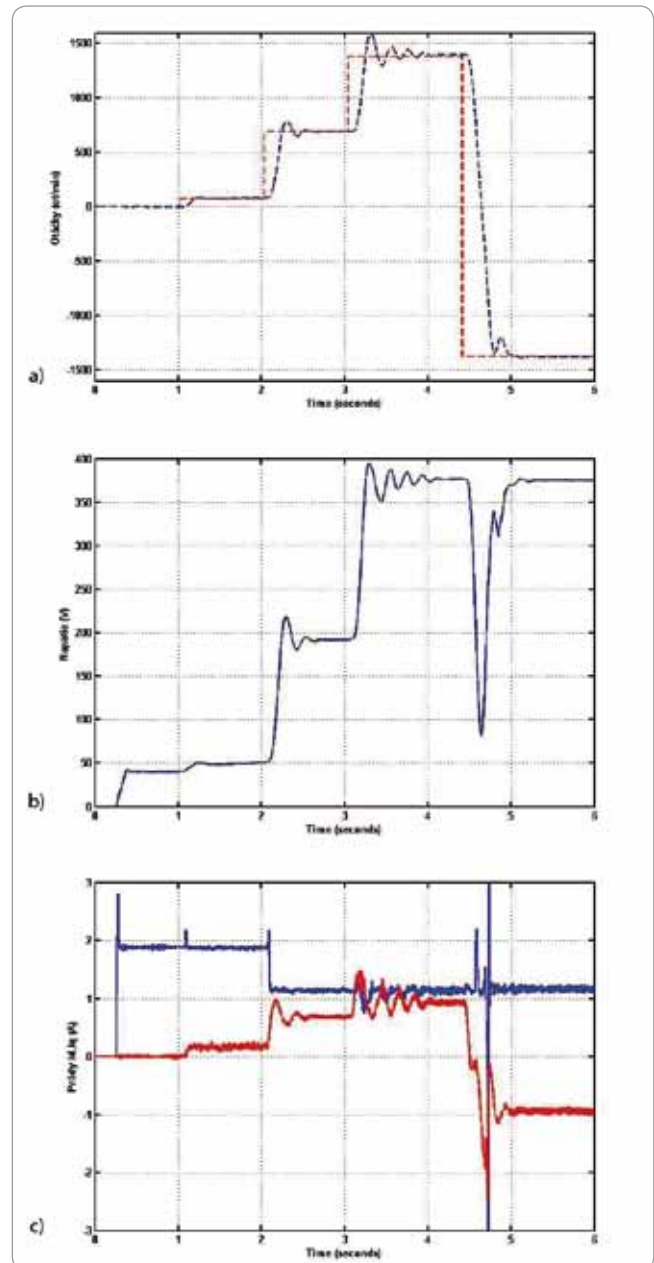
Obr. 4 Principiálna schéma reálneho systému s neurónovým pozorovateľom rýchlosti asynchrónneho motora

V tomto prípade sa informácia o rýchlosti asynchrónneho motora získava z neurónového pozorovateľa vytvoreného v real-time systéme a komunikácia meniča s real-time systémom prebieha prostredníctvom zbernice CAN. Výsledky tohto testovania sú zobrazené na nasledujúcich priebehoch.

Na obr. 5 je zobrazený priebeh otáčok pri zmene žiadanej hodnoty so záťažou. V čase 1 s bola bez záťaženia zadaná zmena rýchlosti z 0 ot./min. na 5 % nominálnych otáčok, v čase 2 s na 50 % nominálnych otáčok, v čase 3 s na 100 % nominálnych otáčok a v čase 4,2 s bola zadaná požiadavka na reverzáciu z hodnoty 100 % nominálnych otáčok na -100 % nominálnych otáčok.

Priebeh žiadanych otáčok je znázornený červenou prerušovanou čiarou a priebeh skutočných otáčok modrou plnou čiarou. Zložka prúdu i_d je zobrazená červenou čiarou a modrou čiarou je zobrazený priebeh zložky prúdu i_q .

- a) otáčky
- b) napätie
- c) prúdy i_d , i_q



Obr. 5 Priebehy otáčok, napätia a zložiek prúdov pri zmene rýchlosti so záťažou

Záver

Tento článok prezentuje výsledky dosiahnuté pri použití umelých neurónových sietí ako pozorovateľov uhlovej rýchlosti pri vektorovom riadení asynchrónneho motora. Z výsledkov simulácií možno vidieť, že pozorovatele založené na báze umelých neurónových sietí sú v porovnaní s klasickými metódami pozorovania veličín dostatočne presné aj napriek tomu, že na ich správnu funkciu nepotrebuje- me poznať bližšie informácie o danom systéme.

Týmto praktickým overením na reálnom modeli sa nám potvrdili naše teoretické predpoklady zo simulácií a bolo dokázané, že neurónové siete možno vďaka ich výhodným vlastnostiam používať na pozorovanie stavových veličín pohonov alebo iných systémov, a to nielen v zapojení s real-time systémom, ale aj inými systémami založenými napríklad na DSP.



Podakovanie

Úloha bola riešená v rámci projektu APVV-0185-10.

Článok vznikol s podporou projektu VaV operačného programu Centrum excelentnosti výkonových elektronických systémov a materiálov pre ich komponenty II. No. OPVaV-2009/2.1/02-SORO, ITMS 26220120046, financovaného Európskym fondom regionálneho rozvoja (ERDF).

Literatúra

- [1] BALARA, Dušan – TIMKO, Jaroslav: Estimation of Induction Parameters using Neural Networks, *Journal of Electrical Engineering*, ISSN 1335-3632, Vol. 50, No. 7 – 8, s. 178 – 184.
- [2] TIMKO, Jaroslav – ŽILKOVÁ, Jaroslava – BALARA, Dušan: Aplikácie umelých neurónových sietí v elektrických pohonoch, Košice: Calypso s. r. o., 2002. ISBN 80-85723-27-1.
- [3] VAS, Peter: Artificial-Intelligence-based electrical machines and drives, Oxford University Press 1999.

Peter Girovský

Milan Lacko

Technická univerzita v Košiciach,
Fakulta elektrotechniky a informatiky,
Katedra elektrotechniky a mechatroniky
Letná 9, 04200 Košice,
peter.girovsky@tuke.sk, milan.lacko@tuke.sk