

# Bezsnímačové vektorové riadenie asynchrónneho motora

Jaroslava Žilková, Jaroslav Timko, Peter Girovský

## Abstrakt

Príspevok sa zaoberá návrhom bezsnímačového vektorového riadenia asynchrónneho motora s kotvou nakrátko s pozorovateľom rýchlosti. Pozorovanie uhlovej rýchlosti asynchrónneho motora je založené na báze dopredných a rekurentných neurónových sietí. Meranými vstupnými veličinami týchto pozorovateľov sú zložky statorového prúdu a statorového napätia motora. V závere príspevku sú uvedené a navzájom porovnané dosiahnuté výsledky experimentov vektorového riadenia asynchrónneho motora s rôznymi štruktúrami neurónových pozorovateľov.

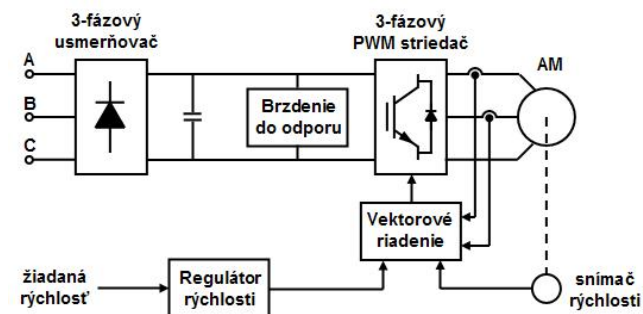
**Kľúčové slová:** Asynchrónny motor (AM), pozorovanie uhlovej rýchlosti, neurónová sieť (Neural Network - NN), dopredná neurónová sieť (FeedForward Neural Network - FFNN), kaskádna neurónová sieť (Cascade Feedforward Neural Network CFNN), Elmanova sieť, vektorové riadenie, bezsnímačové riadenie.

## Úvod

Asynchrónne motory s kotvou nakrátko majú široké uplatnenie v priemyselnej výrobe, k čomu ich predurčujú ich vlastnosti, ako je robustnosť, nízka cena, spoľahlivosť v prevádzke, ľahká údržba a pod.

Jednou z nevýhod asynchrónnych motorov bolo až donedávna ich obtiažne riadenie rýchlosti. Technologický vývoj umožnil za posledné desaťročia jednak znížiť cenu meničov, zvýšiť ich spoľahlivosť a umožnil aplikovať moderné spôsoby riadenia v reálnom čase. Problém zvyšovania kvality pohonu s AM sa tak presunul do oblasti tvorby riadiacich algoritmov, ktoré by čo najviac potlačili nelineárne vlastnosti AM a prípadne umožnili riadenie pohonu aj bez snímača rýchlosti.

Vysokú presnosť riadenia rýchlosti pohonu s asynchrónnym motorom umožňuje dosiahnuť vektorové riadenie, ktoré riadenie asynchrónneho motora zjednodušuje a približuje ho k principiálne jednoduchšiemu riadeniu jednosmerného cudzobudeného motora. Principiálna schéma takéhoto riadenia je znázornená na obr.1.



Obr.1 Schéma vektorového riadenia asynchrónneho motora

Fig.1 Sensorless vector control of an induction motor

Vektorové riadenie AM môže byť orientované na magnetický tok statora, na hlavný magnetický tok a alebo na magnetický tok rotora. Pre vektorové riadenie asynchrónneho motora vo všetkých spomenutých prípadoch potrebujeme poznať stavové veličiny motora, ktorých meranie je buď nemožné, obtiažne, alebo cenovo náročné. Jedným zo spôsobov akým môžeme požadované informácie získať je použitie pozorovateľov stavových veličín, ktoré celý proces riadenia pohonu zjednodušia alebo zlacnia.

Typy pozorovateľov stavových veličín môžeme rozdeliť na:

- pozorovatele využívajúce konštrukčné vlastnosti motora
- pozorovatele na báze matematických modelov
- pozorovatele na báze umelej inteligencie

Pozorovatele založené na báze umelej inteligencie môžeme rozdeliť do niekoľkých kategórií:

- systémy založené na fuzzy logike
- systémy založené na báze neurónových sietí
- systémy založené na báze evolučných algoritmov (genetické algoritmy)
- hybridné systémy založené na kombinácii predchádzajúcich systémov

Vzhľadom na výnimočnú vlastnosť neurónových sietí ako je schopnosť vynikajúco aproximovať zložité nelineárne funkcie, sme návrh pozorovateľa rýchlosti asynchrónneho motora založili na neurónových sieťach.

Samotný návrh neurónových pozorovateľov rýchlosti AM sme rozdelili do niekoľkých krokov:

- výber vhodných veličín motora pre vstupy neurónovej siete, odpovedajúcich výstupu čiže uhlovej rýchlosti motora,
- návrh systému s asynchrónnym motorom pre získanie tréningových množín a pre neskoršie testovanie dosiahnutých výsledkov
- vytvorenie samotných neurónových pozorovateľov
- testovanie neurónových pozorovateľov
- porovnanie vlastností neurónových pozorovateľov

# 1. Neurónový pozorovateľ rýchlosti

Pri návrhu neurónových pozorovateľov je dôležitý výber samotných vstupov neurónovej siete a trénovacej množiny, ktorá musí zohľadňovať všetky stavy, v ktorých bude reálny systém pracovať.

Nami navrhnutý neurónový pozorovateľ uhlovej rýchlosti  $\omega$  vychádza z momentotvornej zložky statorového prúdu  $i_{1y}$  a  $u_{1y}$  – zložky statorového napätia. Vektor vstupných veličín neurónových pozorovateľov predstavujú zložky statorového napätia  $u_{1y}$  a statorového prúdu  $i_{1y}$  v kroku ( $k$ ) a v kroku ( $k-1$ ), u štvorstupových sietí, a v prípade šesť vstupových sietí je tento vektor rozšírený o pozorovanú hodnotu uhlovej rýchlosti v kroku ( $k-1$ ) a kroku ( $k-2$ ).

Závislosť medzi vstupnými a výstupnými veličinami nepredstavuje jednoduchú lineárnu závislosť, preto boli pre pozorovanie uhlovej rýchlosti motora navrhnuté neurónové siete s jednou skrytou vrstvou. Ako aktivačná funkcia pre skrytú vrstvu bola použitá nelineárna tangsmoidná funkcia a pre výstupnú vrstvu bola použitá lineárna aktivačná funkcia.

Cieľom kontrolovaného učenia, pomocou ktorého sme neurónové siete trénovali je, aby neurónová sieť dosiahla takú konfiguráciu, na základe ktorej dokáže realizovať predpísané zobrazenie, teda aproximovať uhlovú rýchlosť motora na základe nižšie uvedených závislostí:

- pre štvorstupové siete:


$$\omega_{(k)} = f[u_{y(k)}, u_{y(k-1)}, i_{y(k)}, i_{y(k-1)}, \underline{w}] \quad (1)$$

- pre šesťvstupové siete:

$$\omega_{(k)} = f[u_{y(k)}, u_{y(k-1)}, i_{y(k)}, i_{y(k-1)}, \omega_{(k-1)}, \omega_{(k-2)}, \underline{w}] \quad (2)$$

kde  $f$  predstavuje vyššie spomínané aktivačné funkcie a vektor  $\underline{w}$  predstavuje vektor váhových a prahových koeficientov neurónových sietí.

Na obr. 2 je zobrazená vybraná trénovacia množina, ktorá je tvorená vstupom: meniacimi sa  $y$ - zložkami napätia a statorového prúdu, a týmto zmenám odpovedajúcemu výstupu: uhlovou rýchlosťou motora. Zmeny uhlovej rýchlosti sú ovplyvnené aj meniacim sa záťažovým momentom, ktorý nie je samostatným vstupom sietí.




Obr.2 Príklad učiacej množiny ( $u_y, i_y, T_L, \omega$ )  
Fig.2 Example of training patterns

Vo všeobecnosti je veľmi obtiažne určiť, ktorý učiaci algoritmus z rozsiahleho počtu dnes známych učiacich algoritmov bude najrýchlejší pre riešenia daného problému. Závisí to od mnohých faktorov vrátane komplexnosti problému, počtu dát v trénovacej množine, počtu parametrov neurónovej siete a požadovanej presnosti. Na základe našich doterajších skúseností sme zvolili Levenberg–Marquardtovu metódu, ktorá je modifikáciou pôvodnej klasickej Newton-Gaussovej metódy pre vyjadrenie minimalizácie sumy kvadrátov, a je veľmi vhodná zvlášť pri požiadavke rýchlej konvergencie a veľkej presnosti učenia.

Pre pozorovanie uhlovej rýchlosti vektorovo riadeného a-synchronného motora sme zvolili tri typy neurónových sietí:

- viacvrstovú doprednú sieť
- kaskádnú doprednú sieť
- Elmanovu sieť

Principiálne schémy navrhnutých neurónových sietí sú zobrazené na obr.3-5.




Obr.3 Dopredná neurónová sieť  
Fig.3 A feedforward neural network

Výstupy prvej a druhej vrstvy doprednej siete sú určené na základe rovníc:

$$\begin{aligned} a_1(k) &= \tan \operatorname{sig}(I w_i + bias_1) \\ a_2(k) &= \operatorname{purelin}(a_1(k) w_j + bias_2) \end{aligned} \quad (3)$$

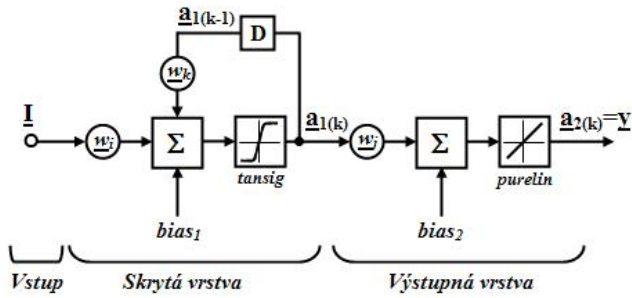
kde  $\operatorname{tansig}$  a  $\operatorname{purelin}$  predstavujú vyššie spomínané aktivačné funkcie,  $I$  predstavuje vektor vstupov a vektor  $\underline{w}$  predstavuje vektor váhových koeficientov neurónovej siete.



Obr.4 Kaskádna neurónová sieť  
Fig.4 A cascade feedforward neural network

Výstupy prvej a druhej vrstvy doprednej kaskádnej siete sú dané vzťahmi:

$$\begin{aligned} a_1(k) &= \tan \operatorname{sig}(I w_i + bias_1) \\ a_2(k) &= \operatorname{purelin}(I w_k + a_1(k) w_j + bias_2) \end{aligned} \quad (4)$$



Obr.5 Elmanova neurónová sieť.  
Fig.5 An Elman neural network

Výstupy prvej a druhej vrstvy Elmanovej siete sú:

$$a_1(k) = \tan sig\left(\frac{I}{w_i} + a_1(k-1)w_k + bias_1\right) \quad (5)$$

$$a_2(k) = purelin\left(a_1(k)w_j + bias_2\right)$$

Trénovanie navrhnutých neurónových sietí prebiehalo off-line na modeli vektorového riadenia asynchrónneho motora s kotvou nakrátko, ktorý bol programovaný v programe Matlab.

## 2. Dosiahnuté výsledky.

V tejto časti sú uvedené dosiahnuté simulačné výsledky bezsnímačového vektorového riadenia asynchrónneho motora pri použití neurónových pozorovateľov rýchlosti.

Simulácie ako aj celý návrh neurónových pozorovateľov bol riešený pre asynchrónny motor s nasledujúcimi parametrami:


$$U = 220 \text{ V}/50 \text{ Hz}, I_N = 6.9 \text{ A}, n_N = 1420 \text{ rpm},$$

$$R_1 = 1.81 \Omega, R_2 = 1.91 \Omega, L_{1\sigma} = L_{2\sigma} = 0.00885 \text{ H},$$


$$L_h = 0.184 \text{ H}, p_p = 2, M_N = 20.17 \text{ Nm}, J = 0.1 \text{ kgm}^2$$

Na nasledujúcich priebehoch sú prezentované dosiahnuté výsledky uhlovej rýchlosti motora pozorované niektorým z neurónových pozorovateľov (plnou čiarou), ktoré sú zároveň porovnané s uhlovou rýchlosťou získanou na základe matematického modelu motora (prerušovaná čiara). Experimenty boli prevedené pri zmenách žiadanej uhlovej rýchlosti, pri spúšťaní motor nebol zaťažovaný pričom v čase  $t=6\text{s}$  bol motor zaťažovaný nominálnym záťažným momentom.


Na obr.6a) je uvedený priebeh rýchlosti pozorovaný doprednou sieťou, na obr.6b) kaskádnou sieťou a na obr.6c) Elmanovou sieťou. Všetky uvedené neurónové siete mali štruktúru 4-6-1 a boli učené na rovnakej tréningovej množine.



a)




b)




c)

Obr.6 Priebehy uhlovej rýchlosti: reálna rýchlosť a rýchlosť pozorovaná pozorovateľmi typu 4-6-1: a) dopredná sieť, b) kaskádna sieť, c) Elmanova sieť

Fig.6 Transients of the rotor speeds: real speed and speeds of 4-6-1 neural estimators: a) FFNN, b) CFNN, c) Elman



a)




b)

Obr.7 Priebehy uhlovej rýchlosti: reálna rýchlosť a rýchlosť pozorovaná pozorovateľmi typu 6-6-1: a) dopredná sieť, b) kaskádna sieť


Fig.7 Transients of the rotor speeds: real speed and speeds of 6-6-1 neural estimators: a) FFNN, b) CFNN

Na obr.7 je plnou čiarou zobrazený priebeh skutočnej hodnoty uhlovej rýchlosti asynchrónneho motora a čiarkovanou čiarou je zobrazená pozorovaná uhlová rýchlosť iba dvoch typov sietí: doprednej a kaskádnej so štruktúrou 6-6-1. Podobne ako v predchádzajúcom prípade neboli Elmanovou sieťou dosiahnuté uspokojivé výsledky.

Na obr. 8 sú zobrazené priebehy želanej a skutočnej rýchlosti riadeného motora vo vektorovom riadení, keď v prípade obr.8a) je použitý pozorovateľ na báze doprednej siete typu 4-6-1 a na obr.8b) pozorovateľ na báze kaskádnej siete typu 4-6-1.



a)



b)

**Obr.8** Priebehy uhlovej rýchlosti pri použití neuronových pozorovateľov typu 4-6-1 v porovnaní so žiadanou hodnotou rýchlosti: a) dopredná sieť, b) kaskádna sieť

**Fig.8** Transients of the rotor speeds for 4-6-1 neural estimators used in the IM F.O.C. compared with reference value of speed: a) FFNN estimator, b) CFNN estimator

## Záver

Príspevok sa zaoberá návrhom neuronových pozorovateľov rýchlosti pre vektorovo riadený asynchrónny motor. Na báze jednoducho merateľných veličín, ako sú zložky statorového prúdu a napätia, boli pre vektorovo riadený asynchrónny motor navrhnuté pozorovatele rýchlosti motora, pričom boli využité dopredné aj rekurentné umelé neuronové siete. Obidva druhy sietí boli učené off-line učením za použitia Levenberg-Marquardtovo učiaceho algoritmu, ktorý je modifikáciou klasického backpropagation učiaceho algoritmu. Pri učení bola u všetkých sietí s rovnakým počtom vstupov použitá rovnaká tréningová množina. Dosiahnuté výsledky, zobrazené na daných priebehoch, potvrdzujú možnosť využitia umelých neuronových sietí pre bezsnímačové vektorové riadenie asynchrónneho motora ako pozorovateľov rýchlosti. Adekvátna presnosť pozorovania uhlovej rýchlosti bola dosiahnutá doprednými a kaskádnymi sieťami. Najlepšie výsledky sme dosiahli pri použití kaskádnej doprednej siete.

## PodĎakovanie

Úloha bola riešená v rámci grantu VEGA č.1/2177/05.

## Literatúra

[1] Vas, P.: Artificial-intelligence-based electrical machines and drives. Oxford University Press, Oxford, 1999.

[2] Vas, P.: Parameter estimation, condition monitoring and diagnosis of electrical machines. Oxford University Press, Oxford, 1993.

[4] Vittek, J., Dodds, S. J.: *Forced dynamics control of electric drives*. ŽU, EDIS Žilina, 2003.

[5] Jovankovič, J., Žalman, M.: *Application of the virtual sensors based on the artificial neural networks*, EDPE'03, International conference, Slovakia, 2003, pp.486-490.

[6] Timko, J., Žilková, J., Balara, D.: "Applications of Artificial Neural Networks in Electrical Drives." (in Slovak), Calypso s.r.o., Košice, 2002, pp.239.

## Abstract

This paper deals with design of sensorless field-oriented control of an induction motor with angular speed neural estimators. Angular speed estimation is based on feedforward and recurrent neural networks. Structures of the ANN estimators are based on measurable motor variables: y-components of stator current and voltage. Various internal structures of neural speed estimators for field-oriented control of induction motor are simulated and their performances are compared, in the end of paper.

**Ing. Jaroslava Žilková, PhD.**

Technická univerzita Košice  
Fakulta elektrotechniky a informatiky  
Katedra elektrotechniky, mechatroniky a priemyselného inžinierstva  
Letná 9  
042 00 Košice  
Tel.: 055/602 2273  
E-mail: jaroslava.zilkova@tuke.sk

**Prof. Ing. Jaroslav Timko, CSc.**

Technická univerzita Košice  
Fakulta elektrotechniky a informatiky  
Katedra elektrotechniky, mechatroniky a priemyselného inžinierstva  
Letná 9  
042 00 Košice  
Tel.: 055/602 2274  
E-mail: jaroslav.timko@tuke.sk

**Ing. Peter Girovský**

Technická univerzita Košice  
Fakulta elektrotechniky a informatiky  
Katedra elektrotechniky, mechatroniky a priemyselného inžinierstva  
Letná 9  
042 00 Košice  
Tel.: 055/602 2270  
E-mail: peter.girovsky@tuke.sk