



ОПРЕДЕЛЯНЕ НА ЪГЛОВАТА СКОРОСТ НА АСИНХРОННИ ЕЛЕКТРОЗАДВИЖВАНИЯ НА БАЗА НЕВРОНЕН MRAS МОДЕЛ С РАЗМИТА АДАПТАЦИЯ НА СКОРОСТТА НА ОБУЧЕНИЕ

ГЕОРГИ ИВАНОВ, СЕВИЛ АХМЕД, ИВАН КОСТОВ

Резюме: *Адаптивните системи с еталонен модел (MRAS) за оценка на скоростта се отличават със стабилност на работа в широк диапазон, сравнително проста реализация и високи динамични и статични показатели. В статията се анализира метод за оценка на скоростта на база невронен MRAS модел, ориентиран по пълния магнитен поток на ротора. Настройваемият модел се реализира като невронна мрежа и скоростта се адаптира посредством градиентен алгоритъм (backpropagation), а скоростта на обучение се определя посредством размит регулатор на Мамдани. Разработеният модел е тестван в симулационната среда на MATLAB/Simulink® и инструментите на Fuzzy Logic Toolbox. Направени са изводи по отношение на точността при работа в режим по задание и компенсация на смущение, а също така и при експлоатация на електрозадвижването в областта на ниските скорости.*

Ключови думи: *безсензорно, скорост, оценка, асинхронен, двигател, изкуствена, невронна, мрежа*

ANGULAR VELOCITY SPEED ESTIMATION OF INDUCTION DRIVES BASED ON NEURAL NETWORK MRAS MODEL WITH FUZZY LEARNING RATE ADAPTATION

GEORGI IVANOV, SEVIL AHMED, IVAN KOSTOV

Abstract: *Model reference adaptive systems (MRAS) for sensorless speed estimation are characterized with robustness and wide operating range, relatively simple implementation and high dynamic and static performance. The article analyzes evaluation method based on the speed of neural MRAS model oriented on rotor flux linkage. Adjustable model is implemented as a neural network and the speed is adjusted by gradient algorithm (backpropagation) and learning rate is determined by fuzzy logic controller (Mamdani). Developed model was tested in simulation environment of MATLAB/Simulink® and instruments of Fuzzy Logic Toolbox. Conclusions are made regarding the accuracy in tracking mode and compensation of disturbances and also during operation of electric power in low speed region.*

Key words: *sensorless, speed, estimation, induction, motor, artificial, neural, network*

1. Въведение

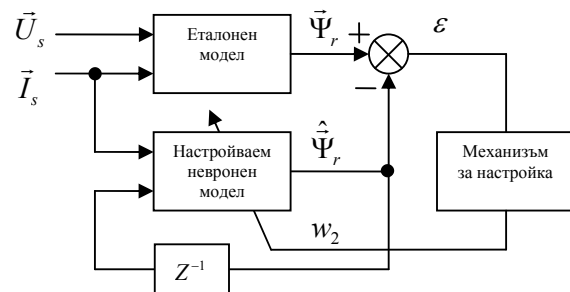
Бързото развитие на системите за управление на електрозадвижванията в последните години се обуславя от редица фактори като усъвършенстване на силовата електроника, цифровите модули за управление (микроконтролери, сигнални процесори) и подобряване на конструкцията на електродвигателите чрез внедряване на спомагателни устройства като датчици за обратни връзки по скорост и път (тахогенератори, импулсни и кодови датчици резолвери и т.н.), по поток (почиващи на ефекта на Хол) и момент (тензодатчици монтирани в лапите на двигателя) [5]. В двигателите се монтират също така елементи на топлинна защита като термистори, позистори и т.н., освен това се предвиждат и вентилатори за принудително охлаждане. Увеличаването на производителността на микропроцесорните системи позволява заместването на електромеханичните датчици за скорост, поток и момент с изчислителни алгоритми, изискващи измерване на лесно достъпните сигнали статорно напрежение и ток [2]. Елиминирането на датчиците е предпоставка за намаляване цената на електрозадвижването, по-голяма компактност и лесна експлоатационна поддръжка, повишава сигурността, особено при работа в неблагоприятна среда и свързано с повишено налягане, температура, влажност и други [10]. Към днешна дата системите за безсензорно управление заемат междинно място между отворените системи и системите с електромеханични обратни връзки по отношение на динамична и статична точност. През последните две десетилетия особен интерес представляват алгоритмите за безсензорно управление на скоростта [2]. Известни са редица изчислителни схеми, реализирани по отворен контур и затворени наблюдатели [10, 11]. От моделите по затворен контур широко приложение намират MRAS схемите, наблюдателите, базирани на филтър на Калман, модел на Люенбергер [10, 11] и в последно време нелинейните наблюдатели, на основата на управление в режим на хлъзгане (*sliding mode control*) [4]. Особено перспективни се явяват невронните мрежи в оценката на скоростта и параметрите на електрозадвижването [6, 11]. Като развитие в тази посока може да се отбележи и предложените невронно-размити механизми с цел повишаване стабилността на работа на тези системи в условията на шум в измерваните сигнали, вариация на параметрите на задвижването и натоварването на механичната част и работа в

областта на ниските скорости [13]. Способността на невронните мрежи за обучение и адаптация, за апроксимация на нелинейни функционални зависимости при сигналите намират приложение при решаването на много от традиционно трудните за класическите методи за управление проблеми. Невронните мрежи са известни още като универсални апроксиматори [7, 8]. Размитата логика от своя страна лесно пресъздава човешки опит и възприятия [12]. Интуитивният подход при създаване на входно-изходни взаимовръзки чрез набор от логически правила превръща размитата логика в широко предпочитана методология за управление и моделиране.

Настоящата работа съчетава двете основни техники на изкуствения интелект в невронен MRAS, който се обучава с адаптивна скорост, изчислена чрез размит лингвистичен модел.

2. Наблюдател на скоростта, базиран на невронен MRAS модел с размита адаптация на скоростта на обучение

В настоящата работа се разглежда невронен MRAS модел за оценка на скоростта, ориентиран по пълния магнитен поток на ротора, а механизмът за настройка представлява градиентен алгоритъм, в който скоростта на обучение се определя на база размита логика. Принципно схема на MRAS модел за оценка на скоростта е представена на фиг. 1:



Фиг. 1. Невронен MRAS модел за оценка на скоростта по пълния магнитен поток на ротора

Еталонният и настройваемият модели представляват съответно напреженовия и токов модели на пълния магнитен поток на ротора [11], като вторият се представя във вид на невронна мрежа и се описва съгласно уравненията [1]:

$$\begin{cases} \hat{\psi}_{r\alpha}(k) = w_1 \hat{\psi}_{r\alpha}(k-1) - w_2 T \hat{\psi}_{r\beta}(k-1) + w_3 i_{s\alpha}(k-1) \\ \hat{\psi}_{r\beta}(k) = w_1 \hat{\psi}_{r\beta}(k-1) + w_2 T \hat{\psi}_{r\alpha}(k-1) + w_3 i_{s\beta}(k-1) \end{cases} \quad (1)$$

където

$$\begin{aligned} w_1 &= 1 - c \\ w_2 &= \omega_r c T_r = \omega_r T \\ w_3 &= c L_m \end{aligned} \quad (2)$$

и $c = T/T_r$.

Теглата w_1 и w_3 са константи, като се адаптира w_2 , което е пропорционално на скоростта с коефициент на пропорционалност стъпката на дискретизация T . Механизмът за настройка представлява градиентен алгоритъм (*backpropagation*) [3] и е изведен на база критерия минимум на квадратичната грешка между изходите на еталонния модел и невронната мрежа. В съответствие с казаното по-горе корекцията на теглото в k -ия такт се получава по уравнение (3):

$$\Delta w_2(k) = -\eta \frac{\partial E}{\partial w_2} \quad (3)$$

където $E = (1/2)\varepsilon^2(k)$.

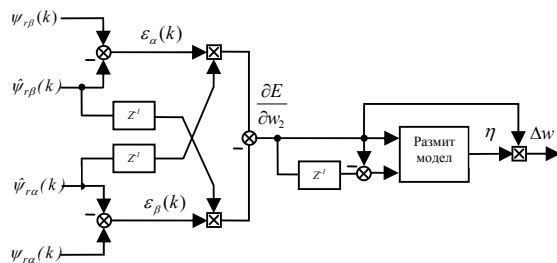
Уравнение (3) може да се развие като се умножи с $\partial \hat{\psi}_r / \partial \hat{\psi}_r$. Оттук следва, че за корекцията на теглото се получава:

$$\Delta w_2(k) = -\eta \frac{\partial E}{\partial w_2} = -\eta \frac{\partial E}{\partial \hat{\psi}_r(k)} \frac{\partial \hat{\psi}_r(k)}{\partial w_2} \quad (4)$$

Текущата стойност на оценката на скоростта, представена в дискретен вид се определя съгласно (3) и (4), като се изразят частните производни и се вземе предвид (2) окончателно се получава:

$$\begin{aligned} \hat{\omega}_r(k) &= \hat{\omega}_r(k-1) + \frac{\Delta w_2(k)}{T} = \\ &= \hat{\omega}_r(k-1) + \frac{\eta}{T} \{ [\psi_{r\beta}(k) - \hat{\psi}_{r\beta}(k)] \hat{\psi}_{r\alpha}(k-1) - \\ &- [\psi_{r\alpha}(k) - \hat{\psi}_{r\alpha}(k)] \hat{\psi}_{r\beta}(k-1) \} \end{aligned} \quad (5)$$

Механизмът за настройка е подробно разгледан в [1, 11]. По-големите стойности на коефициента η водят до по-голяма промяна в теглата, респективно скорост на обучение и сходимост към действителната скорост, но това може да доведе до нежелани осцилации в оценката. Един от подходите за потискане на колебанията в оценката и същевременно запазване на добра сходимост е свързан с адаптивна корекция на скоростта на обучение в зависимост от големината на градиента. За целта е разработен размит механизъм за адаптация на скоростта на обучение η като механизъмът за настройка се реализира по схемата от фиг.2:




Фиг. 2. Градиентен алгоритъм за обучение на невронната мрежа с размита адаптация на скоростта на обучение

Адаптацията на скоростта на обучение се реализира посредством размит модел на Мамдани [9], който на базата на разликата:


$$\begin{aligned} \xi(k) &= [\psi_{r\beta}(k) - \hat{\psi}_{r\beta}(k)] \hat{\psi}_{r\alpha}(k-1) - \\ &- [\psi_{r\alpha}(k) - \hat{\psi}_{r\alpha}(k)] \hat{\psi}_{r\beta}(k-1) \end{aligned} \quad (6)$$

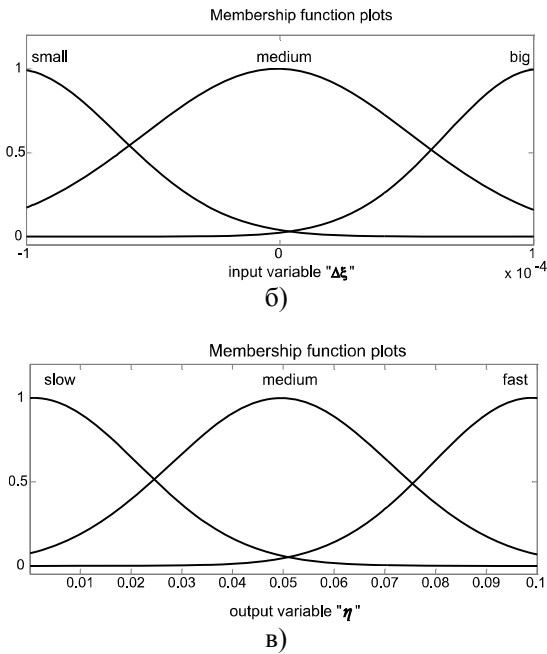
и нейното изменение $\Delta \xi(k) = \xi(k) - \xi(k-1)$ извежда стойност за скоростта на обучение η . Изходът на размития модел, представен чрез фиг.3 участва в адаптацията на теглата на невронната мрежа в схемата на предложения MRAS модел.



Фиг. 3. Размит модел на скоростта на обучение

Входовете на размития модел на скоростта на обучение се размиват с по три Гаусови функции на принадлежност. Същият тип функции са избрани и за изходната величина η в модела на Мамдани (фиг. 4).





Фиг. 4. Разположение на размитите множества за входните а) и б) и изходната в) величини

Лингвистичните стойности за входовете на размития модел са означени със “small”, “medium” и “big”, които съответстват на ниски, средни или големи стойности на променливите $\xi(k)$ и $\Delta\xi(k)$.

Логическите правила, заложили в размития модел на скоростта за обучение, са представени в Табл. 1.

Таблица 1

Логически правила при моделиране на скоростта на обучение

$\xi(k)$ \ $\Delta\xi(k)$	small	medium	big
small	<i>medium</i>	<i>fast</i>	<i>fast</i>
medium	<i>slow</i>	<i>medium</i>	<i>fast</i>
big	<i>slow</i>	<i>slow</i>	<i>medium</i>

Логическите правила, зададени чрез Табл. 1, съответстват на общоприетия запис, който представя причинно-следствената (*if-then, ако-то*) връзка между входно-изходните величини [3]:

- 1) *if* $\xi(k)$ *is* small *and* $\Delta\xi(k)$ *is* small
then η *is* medium
- 2) *if* $\xi(k)$ *is* small *and* $\Delta\xi(k)$ *is* medium
then η *is* slow

- 3) *if* $\xi(k)$ *is* small *and* $\Delta\xi(k)$ *is* big
then η *is* slow
- ⋮
- 9) *if* $\xi(k)$ *is* big *and* $\Delta\xi(k)$ *is* big
then η *is* medium

Предложеният алгоритъм за адаптация на скоростта на обучение чрез размит модел на Мамдани е реализиран чрез Fuzzy Logic Toolbox (FLT) на MATLAB/Simulink®. Разположението на функциите на принадлежност съответства на фиг. 4. Правилата дефинирани в Табл. 1 са въведени чрез редактора на FLT, а за операциите „И“ (“AND”), “ИЛИ“ („OR”), импликация, агрегация и деразвиване са избрани следните методи (Табл. 2):

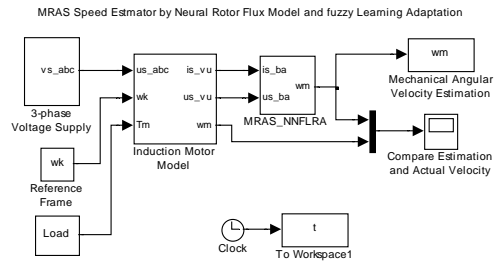
Таблица 2

Параметри на размития модел

„И“	„ИЛИ“	Импликация	Агрегация	Деразвиване
<i>min</i>	<i>max</i>	<i>prod</i>	<i>sum</i>	<i>centroid</i>


3. Симулационни изследвания и резултати

Симулационните изследвания и верификация на предложените модели се реализират в средата на MATLAB/Simulink® чрез следния програмен модел:



Фиг. 5. Модел за безсензорно определяне и верификация на скоростта на АД


Градиентният алгоритъм за настройка на теглото w_2 с управляем коефициент на скоростта на обучение е представен на фиг. 6:



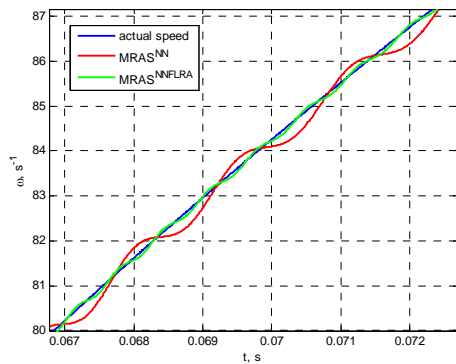
Фиг. 6. Механизъм за настройка на теглото w_2 с адаптация на скоростта на обучение

Изследвана е работата на разработения модел за оценка на скоростта в режим на

следене и компенсация на смущение. За целта се използва модел на двигател тип АД-90S-4, с каталожните параметри, представени в [1] и се управлява по честотния закон U/f^n , а смущението се представя като промяна в натоварването на машината. На фиг.7 и фиг.8 са представени преходните процеси при пускане на АД, като скоростта от модела на двигателя се отбелязва като *actual speed*, MRAS модела базиран на невронна мрежа – $MRAS^{NN}$, а модифицирания MRAS модел с адаптивна скорост на обучение се бележи като $MRAS^{NNFLRA}$. Трябва да се отбележи, че при $MRAS^{NN}$ скоростта на адаптация – η е твърдо заложена като стойност – 0.01, докато при $MRAS^{NNFLRA}$ се развива в границите $\eta=0.00001\div 0.1$



Фиг. 7. Преходни процеси при пускане на АД

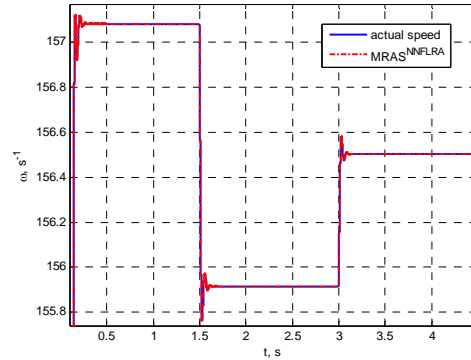


Фиг. 8. Преходни процеси в началния участък при пускане на АД


Интерес представлява поведението на синтезирания наблюдател при промяна на натоварването, представено на фиг.9. За разглеждания случай машината се развърта ненатоварена като в момента $t=1.5s$ се прилага номинален съпротивителен момент ($M_c = M_{сн}$), а в третата секунда $M_c = 0.5M_{сн}$.

Оценка на работата на наблюдателя се прави и в режим на следене като заданието за скоростта на двигателя се променя стъпално през равни интервали - 380V/50Hz и 190V/25Hz.


Резултатите от това изследване се представят на фиг.10 като заданието се изменя на всяка секунда.



Фиг. 9. Преходни процеси при промяна на натоварването



Фиг. 10. Преходни процеси при промяна на заданието на скоростта



Фиг. 11. Преходни процеси при ниска скорост и промяна в натоварването

Важен показател за оценка устойчивостта на работа на невронния MRAS наблюдател на скоростта с размита адаптация на скоростта на обучение е при задания около и по ниски от 1Hz. В тази връзка на фиг.11 е представена графика на преходния процес при ъглова скорост на полето на машината 3.14 rad/s и промяна на натоварването.

Като количествен показател за работата на синтезирания модел за оценка на скоростта ($\hat{\omega}_{mi}$) се използват средноквадратичната (ε_{mse}) и максималната (ε_{max}) грешки (Табл.3) получени по формули:

$$\varepsilon_{mse} = \frac{\sum_{i=1}^n (\omega_{mi} - \hat{\omega}_{mi})^2}{n}, \quad i = 1 \div n \quad (7)$$

$$\varepsilon_{max} = \max(|\omega_{mi} - \hat{\omega}_{mi}|)$$

където с n се бележи броят на изчисленията.

Таблица 3

	MRAS	MRAS ^{NN}	MRAS ^{NNFLRA}
ε_{mse}	0.632	0.0013	0.00014
ε_{max}	4.156	0.5628	0.2429

4. Заключение

В настоящата статия е представен невронен оценител на скоростта на асинхронен двигател. Схемата за оценка е резлизирана посредством MRAS модел, базиран на двуслойна невронна мрежа с градиентен метод за обучение. Акцентът в статията е поставен върху адаптивната скорост на обучение, която се основава на размит модел с два входа и участва в процедурата за актуализация на теглата на невронния MRAS. Необходимостта от променлива скорост в избрания градиентен обучаващ алгоритъм е обусловена от специфичната динамика на изследвания обект и от изискванията за точност на оценката.

Проведените симулационни изследвания доказват необходимостта от прилагане на адаптивна скорост на обучение с оглед подобряване на сходимостта и намаляване на нежеланите осцилации в оценката на ъгловата скорост на машината.

ЛИТЕРАТУРА

- Иванов Г., Д. Спиров,** Оценка на ъгловата скорост на асинхронни електрозадвижвания на база невронен MRAS модел, Journal of the Technical University – Sofia Plovdiv branch, Bulgaria, “Fundamental Sciences and Applications” Vol. 19, 2013, ICETS TECHSYS 2013.
- Михов М. Р.,** Системи за управление на електрозадвижванията, ТУ-София, София, 2009г.
- Петров М., А. Топалов, А. Танева, Н. Шакев,** Методи на изкуствения интелект в системите за управление, Пловдив, 2009.
- Boldea I, C. Lascu, F. Blaabjerg,** „A Class of Speed-Sensorless Sliding-Mode Observers for

High-Performance Induction Motor Drives”, IEEE Trans. on Industrial Electronics, vol. 56, no. 9, September 2009, pp.3394-340

5. Bose B., Power Electronics and Motor Drives - Advances and Trends, Academic press, 2006.

6. Bose B., Neural Network Applications in Power Electronics and Motor Drives – An Introduction and Perspective. IEEE Transactions on Industrial Electronics, Vol. 54, No.1, pp.14-33, 2007.

7. Funahashi K., On the approximate realisation of continuous mapping by neural networks. Neural Networks 2, 1989, pp. 183–192.

8. Hornik K., M. Stinchcombe, H. White, Multilayer feedforward networks are universal approximators, Neural Networks, Volume 2, Issue 5, 1989, pp. 359-366, ISSN 0893-6080, 10.1016/0893-6080(89)90020-8.

9. Mamdani E. H., Application of fuzzy logic to approximate reasoning using linguistic synthesis, IEEE Transactions on Computers 26(12): pp. 1182-1191, 1977.

10. Tarchala G., M. Dybkowski, T. Orłowska-Kowalska, Analysis of the chosen speed and flux estimators for sensorless induction motor drive, International Symposium on Industrial Electronics (ISIE), pp. 525-530, 2011.

11. Vas P., Sensorless Vector and Direct Torque Control. Oxford University Press, 1998.

12. Zadeh L., Fuzzy sets. Information and Control, 8: pp. 338-353, 1965.

13. Zerikat M., Fuzzy-neural networks controller-based adaptation mechanism for sensorless induction motor drives. IEEE Transactions on Industrial Electronics, Vol. 54, No.1, pp.14-33, 2007.

Работата по статията е в съответствие с проект на НИС на ТУ-София № 122ПД0031-19 от 09.05.2012 г на тема *Развойна платформа за цифрово управление на асинхронно електрозадвижване.*

Department of Control Systems
 Technical University–Sofia, Branch Plovdiv
 25 Tsanko Dyustabanov St.
 4000 Plovdiv
 BULGARIA
 E-mail: georgi.iwanow@gmail.com
 E-mail: sevil.ahmed@tu-plovdiv.bg
 E-mail: ijk@tu-plovdiv.bg

Постъпила на
 Рецензент