

Identifikácia parametrov asynchrónneho motora genetickým algoritmom

Marián Jančovič, Milan Žalman

Cieľom tohto článku je ukázať možnosť použitia genetických algoritmov na identifikáciu parametrov asynchrónneho motora s kotvou nakrátko – AM. Opisuje sa základný postup pri aplikácii genetického algoritmu a uvádza sa konkrétny príklad jeho použitia pre identifikáciu parametrov AM. Genetický algoritmus umožňuje identifikovať parametre motora aj pri zašumených a kvantovaných meraných signáloch prúdu s vyhovujúcou presnosťou.

Úvod

Pozorovatele stavových veličín a parametrov sú nevyhnutnou súčasťou algoritmov riadenia polohových a rýchlostných servopohonov s AM. Základné rozdelenie metód identifikácie vychádza z množiny merateľných veličín motora. Podľa toho môžeme klasifikovať pozorovatele do týchto kategórií:

- s meraním napätia, prúdu a uhlovej rýchlosti $\hat{u}_{s\alpha}, \hat{i}_{s\alpha}, \omega$,
- s meraním prúdu a uhlovej rýchlosti $\hat{i}_{s\alpha}, \omega$,
– uplatňujú sa v štruktúrach riadenia s meraním uhlovej rýchlosti
- s meraním napätia, prúdu $\hat{u}_{s\alpha}, \hat{i}_{s\alpha}$,
– uplatňujú sa v štruktúrach riadenia bez priameho merania uhlovej rýchlosti – v tzv. bezsnímačových štruktúrach riadenia.

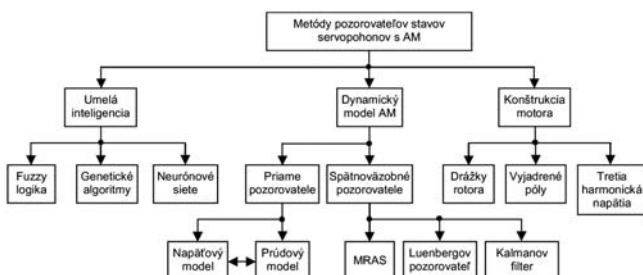
Základná klasifikácia metód pozorovania stavových a identifikáciu veličín servopohonov s AM je uvedená na obr. 1. Podľa tejto klasifikácie možno definovať:

Pozorovatele vychádzajúce z dynamického modelu AM

- Priame pozorovatele využívajúce merané statorové napätia a prúdy
- Adaptívne systémy s referenčným modelom MRAS (Model Reference Adaptive Systems)
- Spätnoväzbové pozorovatele s adaptáciou (Kalman, Luenberger)

Pozorovatele s umelou inteligenciou

- Systémy založené na fuzzy logike
- Neurónové siete
- Neurónové fuzzy systémy
- Evolučné algoritmy (genetické algoritmy)



Obr.1 Metódy pozorovania stavových veličín a parametrov servopohonov s AM

Pozorovatele využívajúce vlastnosti konštrukcie motora

- Vyjadrené póly motora, drážky rotora, asymetria vzduchovej medzery
- Tretiu harmonickú napätia spôsobenú nasýtením magnetického obvodu
- Využitie superponovania signálov

Na identifikáciu parametrov AM môže byť použitý aj genetický algoritmus (GA) ako stochastický off-line optimalizačný algoritmus. GA využívajú zákony prirodzeného výberu na nájdenie najvhodnejšieho riešenia spomedzi všetkých reprezentantov. Podobne ako iné optimalizačné postupy vyžadujú formuláciu účelovej funkcie (tzv. fitness), ktorá reprezentuje samotný optimalizovaný problém. Ich najväčšou výhodou je, že sa dokážu dostať z okolia lokálnych extrémov, kde môžu iné optimalizačné metódy uviaznuť a sú schopné nájsť alebo sa aspoň priblížiť ku globálnemu optimu. Avšak aj GA, podobne ako iné metódy, majú svoje nevýhody. Najväčšou nevýhodou metódy GA je veľká výpočtová a tým aj časová náročnosť, ktorú však možno znižovať optimalizáciou jednotlivých parametrov.

Identifikácia parametrov AM prostredníctvom GA je založená na vyhodnotení účelovej funkcie, ktorá porovnáva vstupno-výstupné údaje z asynchrónneho motora a jeho simulačného modelu. Cieľom príspevku je ukázať, že na rozdiel od iných metód identifikácie je implementácia metódy GA jednoduchá a nevyžaduje si príliš veľké úsilie. Na druhej strane však ide o proces veľmi pomalý, čo vyplýva zo zložitosti a nelineárnosti AM, počtu identifikovaných parametrov a tým aj počtu potrebných generácií na dosiahnutie uspokojivého riešenia.

1. Matematický model AM

Pri identifikácii parametrov AM vychádzame z modelu AM v súradnicovom systéme statora uvedený v [2], v ktorom pre zložky statorového prúdu platia vzťahy:

$$i_{s\alpha} = \frac{1}{R_1 + L_s' s} \left(u_{s\alpha} + \frac{k_r}{T_r} \Psi_{r\alpha} + k_r \Psi_{r\beta} \omega \right) \quad (1)$$

$$i_{s\beta} = \frac{1}{R_1 + L_s' s} \left(u_{s\beta} + \frac{k_r}{T_r} \Psi_{r\beta} + k_r \Psi_{r\alpha} \omega \right) \quad (2)$$

kde



$$R_1 = R_s + R_r \frac{L_m^2}{L_r^2} \quad (3)$$

$$L_s' = \sigma L_s \quad \sigma = 1 - \frac{L_m^2}{L_s L_r} \quad (4)$$

$$T_1 = \frac{L_s'}{R_1} \quad (5)$$

$$T_r = \frac{L_r}{R_r} \quad (6)$$

$$k_r = \frac{L_m}{L_r} \quad (7)$$

Zložky magnetického toku rotora v statorovom súradnicovom systéme vyjadrujú tieto vzťahy:

$$\Psi_{r\alpha} = \frac{L_m}{1+sT_r} \left(i_{s\alpha} - \omega \Psi_{r\beta} \frac{T_r}{L_m} \right) \quad (8)$$

$$\Psi_{r\beta} = \frac{L_m}{1+sT_r} \left(i_{s\beta} - \omega \Psi_{r\alpha} \frac{T_r}{L_m} \right) \quad (9)$$

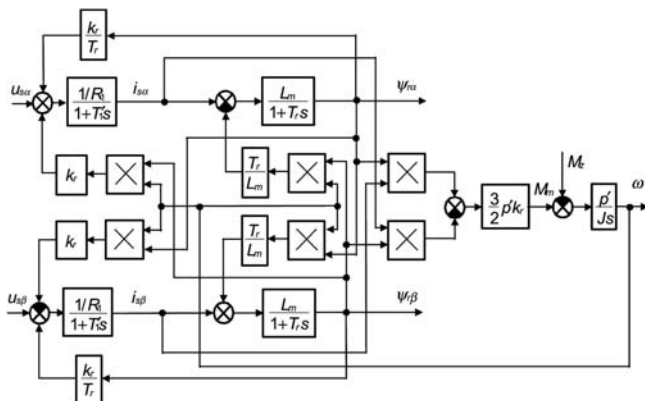
Pre moment platí vzťah:

$$M_m = \frac{3}{2} p' \frac{L_m}{L_r} \Im(\hat{\Psi}_r^* \hat{i}_s) = \frac{3}{2} p' \frac{L_m}{L_r} (\Psi_{r\alpha} i_{s\beta} - \Psi_{r\beta} i_{s\alpha}) \quad (10)$$

$$M_m - M_z = J \frac{d\omega_m}{dt} \quad (11)$$

$$\omega = p' \omega_m \quad (12)$$

Na obr. 2 je znázornená bloková schéma napätového modelu AM v súradnicovom systéme statora.



Obr.2 Bloková schéma modelu AM v súradnicovom systéme statora

2. Teoretický rozbor metódy GA

V tejto časti rozoberieme konkrétnu aplikáciu GA na identifikáciu parametrov AM. Bližšie oboznámenie sa s genetickým algoritmom a jeho vlastnosťami je možné napr. v [3], [4], [5].

Základnými prvkami genetického algoritmu sú gény, ktoré spolu vytvárajú chromozóm. Chromozóm, nazývaný aj reťazec alebo jedinec, predstavuje skupinu hľadaných parametrov – génov, t. j. potenciálne riešenie daného problému. Pri identifikácii AM reprezentujú gény tieto hľadané parametre:

- R_s – odpor statora,
- R_r – odpor rotora,
- L_s – indukčnosť statora,
- L_r – indukčnosť rotora,
- L_m – magnetizačná indukčnosť,
- J – moment zotrvačnosti.

Hodnoty týchto parametrov musia byť zakódované v chromozómovej reprezentácii. Parametre L_s a L_r sú lineárne závislé [6]

a rozdiely medzi ich hodnotami bývajú zvyčajne veľmi malé, resp. žiadne. Preto budeme uvažovať zjednodušujúci predpoklad $L_r = L_s$, čím zredukujeme počet identifikovaných parametrov a chromozóm genetického algoritmu bude mať potom tvar:

$$r = (R_s, R_r, L_s, L_m, J) \quad (13)$$

Spôsob reprezentácie hľadaných parametrov môže byť rôzny, napr. binárno-číselná, celočíselná, reálno-číselná, symbolová a závisí od charakteru daného problému. V prípade identifikácie parametrov AM je vhodné použiť reálno-číselné hodnoty, pretože pri použití reálno-číselného kódovania sa na rozdiel od binárneho kódovania hodnoty génov menia spojitou, úmerne žiadanej veľkosti zmeny a priebeh riešenie býva stabilnejšie.

Pre hodnoty génov treba definovať prípustné intervaly hodnôt, t. j. určiť rozsahy jednotlivých parametrov. Čím užšie vieme ohraničiť prehľadávaný priestor, tým viac urýchlíme riešenie. A naopak príliš veľkým obmedzením rozsahov môžeme vylúčiť optimálne riešenie. Pri ich určovaní môžeme vychádzať z apriórnych informácií, napr. z katalógových hodnôt.

Rýchlosť riešenia ovplyvňujeme aj voľbou veľkosti populácie, ktorá predstavuje skupinu chromozómov, resp. potenciálnych riešení v danej časovej etape (generácii). Tá môže závisieť od konkrétneho prípadu. Pri väčšine úloh sa však odporúča voliť jej veľkosť medzi 10 až 100, najčastejšie medzi 20 a 50. Pri malých populáciách nebýva dostatočný priestor na rôznorodosť (diverzitu) genetických informácií, pri príliš veľkých populáciách sa už nedosahuje lepší efekt a riešenie sa predlžuje. To znamená, že čím je populácia väčšia, tým viac vyčíslení účelovej funkcie treba realizovať a tým dlhšie trvá realizácia GA. Avšak na druhej strane zväčšovaním populácie sa zväčšuje počet potenciálnych riešení a dáva sa tým priestor pre väčšiu diverzitu medzi jedincami, čím sa zabezpečuje širší záber prehľadávaného priestoru a znižuje riziko uviaznutia v lokálnom extréme.

Nastavenie hodnôt génov začiatočnej populácie reťazcov sa najčastejšie realizuje inicializáciou náhodnými hodnotami. Avšak na urýchlienie riešenia sa môžu tieto hodnoty nastaviť podľa apriórnych vedomostí o procese. Vhodnosť jednotlivých reťazcov parametrov (13) sa vyhodnocuje účelovou funkciou. V tomto prípade sa účelová funkcia skladá z dvoch častí. Najskôr sa aktuálny reťazec parametrov prekopíruje do simulačného modelu a následnou simuláciou dynamického systému vhodným číslícovým prostriedkom, ktorý dokáže čo najlepšie napodobniť správanie reálneho systému, sa získajú vstupno-výstupné údaje. V druhej časti sa dosadením výstupných údajov z reálneho systému a údajov zo simulácie vyčíslí vhodná kritériálna funkcia. Minimalizáciou kritériálnej funkcie sa dosiahne priblíženie identifikovaných hodnôt parametrov systému k ich reálnym hodnotám. V prípade identifikácie parametrov možno výhodne použiť integrálne kritériá kvality ako napríklad:

$$F = \int_0^T (y - y_m)^2 dt \quad (14)$$

kde y_m je výstup simulovaného modelu a y – výstup reálneho systému.

V našom prípade predstavuje reálny systém asynchrónny motor, ktorého vstupnými veličinami sú zložky statorového napätia $u_{s\alpha}$ a $u_{s\beta}$ a výstupnými zložky statorového prúdu $i_{s\alpha}$ a $i_{s\beta}$. Potom kritériálna funkcia bude mať tvar:

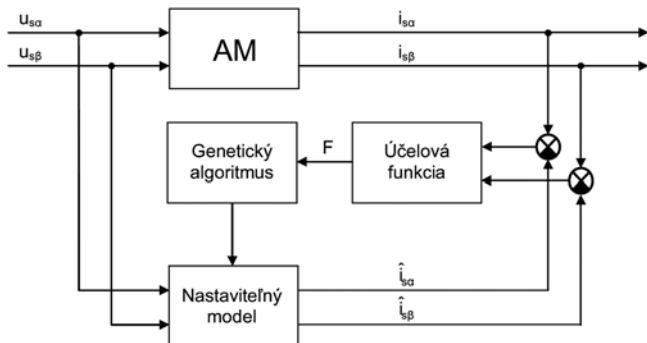
$$F = \sum_{k=1}^N (i_{s\alpha k} - \hat{i}_{s\alpha k})^2 + \sum_{k=1}^N (i_{s\beta k} - \hat{i}_{s\beta k})^2 \quad (15)$$

kde $i_{s\alpha k}$ je hodnota k -tej vzorky tokotvornej zložky prúdu z reálneho zariadenia,

$\hat{i}_{s\alpha k}$ – hodnota k -tej vzorky tokotvornej zložky prúdu z modelu,

- $i_{s\beta i}$ – je hodnota k -tej vzorky momentotvornej zložky prúdu z reálneho zariadenia,
- $\hat{i}_{s\beta i}$ – hodnota k -tej vzorky momentotvornej zložky prúdu z modelu,
- N – počet vzoriek a
- F – hodnota účelovej funkcie.

Implementácia genetického algoritmu na získanie parametrov AM je znázornená na obr. 3, kde účelová funkcia vyhodnocuje rozdiel medzi zložkami prúdu reálneho systému a modelu.




Obr.3 Princíp identifikácie parametrov AM použitím genetického algoritmu

Po vyčíslení fitness funkcie všetkých reťazcov nasleduje na základe tejto fitness hodnoty výber jedincov do novej populácie a výber jedincov do pracovnej skupiny, nad ktorou sa potom realizujú genetické operácie kríženia a mutácie. Okrem výberu jedincov na základe ich fitness sa často používajú aj iné metódy, napr. náhodný, ruletový, turnajový výber a pod. Priamym skopírovaním najlepšieho jedinca, prípadne niekoľkých jedincov do novej populácie sa zabezpečuje konvergencia riešenia.


Na reťazce v pracovnej skupine sú potom aplikované operácie kríženia a mutácie. Operácia kríženia zabezpečuje rýchlu výmenu výhodných vlastností medzi chromozómami, ktoré podstatne zvyšujú fitness chromozómov. Jej princíp spočíva v rozdelení (najčastejšie dvoch) rodičovských reťazcov na dve alebo viac častí v náhodne zvolených pozíciách (pre všetky reťazce rovnakých). Vzájomnou výmenou týchto rozdelených častí potom vzniknú nové reťazce – potomkovia. Na obr. 4 je znázornené jednobodové kríženie, pri ktorom sa náhodne vygeneruje bod kríženia a chromozómy si vymenia svoje časti za týmto bodom.

Operácia mutácie zanáša do chromozómov novú informáciu, ktorá môže zvýšiť fitness chromozómov. Náhodne vybraný reťazec sa v jednom alebo viacerých náhodne vybraných génoch náhodne modifikuje. Príklad mutácie jedného génu v reťazci je znázornené na obr. 5.

Nastavením výberu jedincov do novej populácie a spôsobu kríženia a mutácie môžeme ovplyvniť rýchlosť a efektívnosť riešenia, ale aj riziko uviaznutia v lokálnom extréme. Existuje veľmi veľa možností a kombinácií týchto nastavení. Ak by sme použili iba



Obr.4 Jednobodové kríženie dvoch reťazcov



Obr.5 Mutácia reťazca

operáciu kríženia, po vyčerpaní všetkých kombinácií by sme už nedostávali nové parametre a tým ani lepšie riešenia. Tie zabezpečuje mutácia, ktorá spočíva v pridaní náhodnej hodnoty do aktuálnej hodnoty parametra. Klasická mutácia nahrádza aktuálnu hodnotu hodnotou z ohraničeného intervalu, ktorý bol definovaný ako oblasť možných hodnôt pre daný parameter. Keď je však vzdialenosť medzi aktuálnou hodnotou parametra a jeho optimálnou hodnotou v porovnaní so vzdialenosťou medzi hornou a dolnou hranicou intervalu malá, možnosť pridať novú vhodnú hodnotu sa stane veľmi malou. V tomto prípade by genetický algoritmus konvergoval rýchlo až do určitého okolia optimálneho riešenia a potom by trvalo dlhý čas urobiť zvyšok. Riešenie môže spočívať v zmene šírky tohto intervalu alebo v použití aditívnej alebo multiplikatívnej mutácie, ktorá k aktuálnej hodnote pripočítava náhodnú hodnotu zo zvoleného rozsahu, resp. ju ňou vynásobí.

Pri použití reálno-číselného kódovania možno aplikovať operáciu medziľahlého kríženia, ktorá je istou kombináciou kríženia a mutácie. Nový potomok vznikne z dvoch rodičovských reťazcov podľa vzťahu:

$$p = r_1 + \alpha(r_2 - r_1) \quad (16)$$

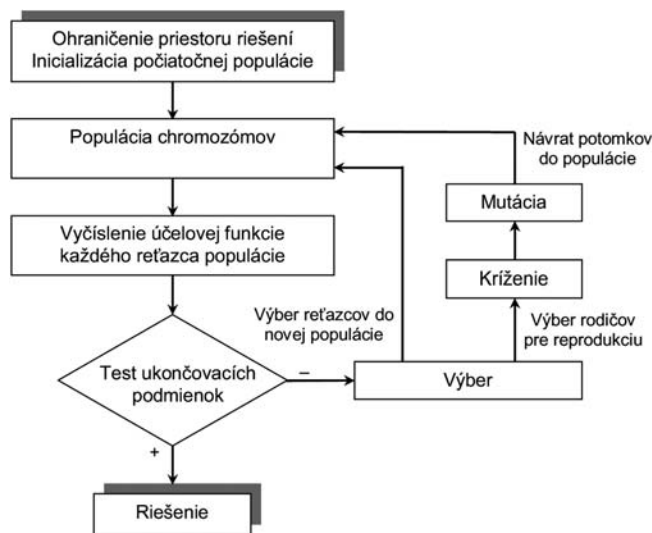
kde p je nový potomok,

r_1 a r_2 sú rodičovské reťazce a

α je náhodné číslo z rozsahu $0,25 < \alpha < 1,25$.

Ukončenie genetického algoritmu môže byť realizované viacerými spôsobmi. Napríklad GA môže byť ukončený, ak hodnota účelovej funkcie dosiahne určitú minimálnu hodnotu. Najjednoduchšie riešenie predstavuje ukončenie GA za konečný počet generácií.

Znázornenie postupnosti operácií genetického algoritmu je na obr. 6. Pri štarte GA sa ohraničí prehľadávaný priestor, zvolí sa veľkosť populácie a náhodne sa vygeneruje alebo zadá štartovacia populácia reťazcov. Potom sa vyhodnotí hodnota účelovej funkcie každého reťazca. Z celej populácie sa vyberie istý počet najúspešnejších reťazcov (s najlepšimi hodnotami účelovej funkcie), ktoré sa bez zmeny prekopírujú do novej populácie. Okrem toho sa z rodičovskej populácie jedným z viacerých možných spôsobov vyberie iná skupina pracovných reťazcov, s ktorou sa uskutočňujú operácie kríženia a mutácie. Z nich vznikne rovnaký počet nových reťazcov potomkov. Tie sa spoja s predtým vybranými najúspešnejšími reťazcami a spolu vytvoria novú rodičovskú populáciu, s ktorou sa celá procedúra opakuje. Algoritmus sa vykonáva dovtedy, kým najlepší reťazec nedosiahne požadovanú hodnotu účelovej funkcie alebo kým sa nedosiahne predpísaný počet generácií.



Obr.6 Schematické znázornenie genetického algoritmu

3. Overenie metódy identifikácie na simulačnom modeli AM

Na overenie navrhnutého genetického algoritmu využijeme prostredie Matlab/Simulink a nástroje Genetic Toolbox-u [5]. Namiesto reálneho zariadenia použijeme simulačný model AM podľa obr. 2. Pri simuláciách bola použitá perióda vzorkovania 0,25 ms. Oblasť riešení jednotlivých parametrov bola definovaná týmito intervalmi:

$$R_s \in \langle 1; 10 \rangle \quad R_r \in \langle 1; 5 \rangle \quad L_s \in \langle 0,1; 1 \rangle$$

$$L_m \in \langle 0,1; 1 \rangle \quad J \in \langle 0,0001; 0,1 \rangle$$

Vzhľadom na veľkosť chromozómu sa využíval GA s 50 chromozómami, t. j. s 50 kombináciami hľadaných parametrov AM. Hodnoty parametrov v začiatkovej generácii sa inicializovali náhodnými hodnotami. Genetický algoritmus bol ukončený po konečnom počte 500 generácií.

Navrhnutý GA na identifikáciu parametrov AM môžeme opísať týmito bodmi:

1. Na začiatku sa náhodne vygeneruje populácia 50 reťazcov v danom intervale.
2. Postupne sa priradí všetkých 50 chromozómov do simulačného modelu realizovaného podľa blokovej schémy na obr. 2. Na vstup modelu je privedený sínusový priebeh napätia $u_{s\alpha}$ a sínusový priebeh napätia $u_{s\beta}$ s rovnakou amplitúdou a frekvenciou, ale s fázovým posunom $-\pi/2$. Po simulácii, ktorá trvá 2 s, sa vyhodnotí zvolená kritériálna funkcia. Úlohou GA je minimalizovať túto funkciu. Keďže pri simuláciách používame periódu vzorkovania 0,25 ms, znamená to použitie 8 000 vzoriek výstupných signálov po pripojení vstupného napätia, t. j. rozbehu motora.
3. Do novej populácie sa prekopíruje chromozóm s najnižšou a chromozóm s druhou najnižšou hodnotou kritériálnej funkcie.

4. Do pracovnej skupiny sa prekopíruje 5-krát chromozóm s najnižšou, 3-krát chromozóm s druhou najnižšou, 3-krát chromozóm s treťou najnižšou, 2-krát chromozóm so štvrtou najnižšou, 2-krát chromozóm s piatou najnižšou a 1-krát chromozóm so šiestou najnižšou hodnotou kritériálnej funkcie.
5. Do pracovnej skupiny sa skopíruje 32 náhodne vybraných chromozómov.
6. Na pracovnú skupinu sa aplikuje operácia jednobodového kríženia, pričom výber párov pre kríženie je náhodný.
7. Na pracovnú skupinu sa aplikuje operácia multiplikatívnej mutácie s pravdepodobnosťou mutácie génu 0,1, ktorá hodnotu vybraného génu vynásobí náhodným číslom z rozsahu (0; 2).
8. Na pracovnú skupinu sa aplikuje operácia medziľahlého kríženia s náhodným výberom krížených dvojíc, pričom $\alpha = 1,25$.
9. Pracovná skupina je presunutá do novej populácie.
10. Algoritmus sa opakuje s novou populáciou, kým sa nedosiahne 500 generácií. Potom je najlepší reťazec vyhodnotený ako najlepšie riešenie.

Použitie navrhnutého genetického algoritmu sa overoval pre rôzne hodnoty amplitúdy a frekvencie vstupných napätí. Výsledky z jednotlivých identifikácií sú uvedené v tab. 1, kde sú vyjadrené aj percentuálne odchýlky týchto výsledkov od skutočných parametrov. Z tabuľky možno vidieť, že čím je vyššia frekvencia vstupného signálu, tým je po 500 generáciách dosiahnutá menšia presnosť identifikácie. To znamená, že zvyšovaním frekvencie napätia treba zvyšovať aj počet použitých generácií identifikácie na dosiahnutie požadovanej presnosti.

Aby sa overilo, že výsledok identifikácie nebol náhodný, realizoval sa experiment identifikácie genetickým algoritmom viackrát pri rovnakom vstupnom napätí. V tab. 2 sú výsledky piatich pokusov identifikácie parametrov modelu AM pri vstupných napätiach s amplitúdou 15 V a frekvenciou 10 Hz. Na obr. 7 je

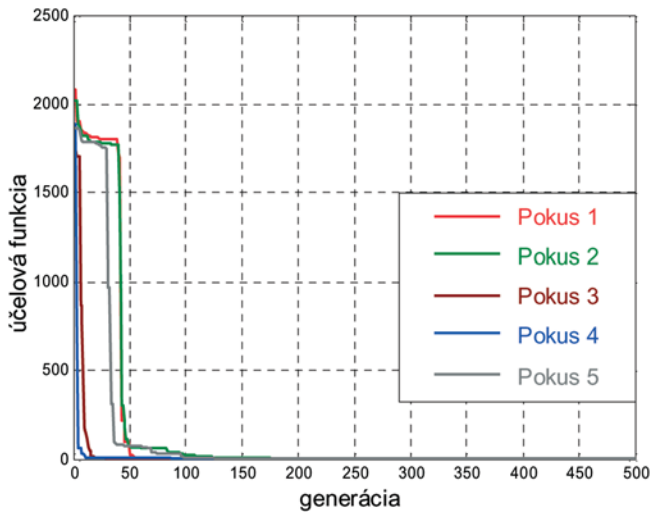
		R_s	R_r	L_s	L_m	J
	skutočná hodnota	7,608	3,7	0,6015	0,5796	0,0017
7,5 V, 5 Hz $F = 1,5062 \cdot 10^{-3}$	identifikovaná hodnota	7,5954	3,7093	0,60227	0,58047	0,0017059
	relatívna chyba	-0,166 %	0,251 %	0,127 %	0,150 %	0,350 %
15 V, 10 Hz $F = 1,6439 \cdot 10^{-2}$	identifikovaná hodnota	7,5587	3,7269	0,60204	0,58028	0,0017174
	relatívna chyba	-0,648 %	0,726 %	0,090 %	0,117 %	1,021 %
30 V, 20 Hz $F = 1,8171$	identifikovaná hodnota	7,4066	3,8124	0,62926	0,60741	0,0017529
	relatívna chyba	-2,647 %	3,039 %	4,616 %	4,799 %	3,111 %
45 V, 30 Hz $F = 15,3852$	identifikovaná hodnota	7,2382	3,9168	0,70633	0,68436	0,0018073
	relatívna chyba	-4,861 %	5,858 %	17,43 %	18,07 %	6,311 %

Tab.1 Porovnanie výsledkov identifikácie parametrov AM genetickým algoritmom pri rôznych hodnotách amplitúdy a frekvencie vstupného napätia s ich skutočnými hodnotami

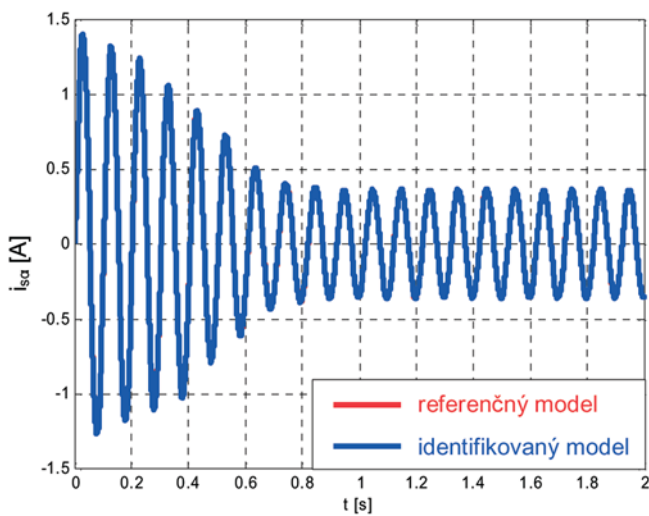
		R_s	R_r	L_s	L_m	J
	skutočná hodnota	7,608	3,7	0,6015	0,5796	0,0017
pokus 1 $F = 1,6439 \cdot 10^{-2}$	identifikovaná hodnota	7,5585	3,7269	0,60204	0,58028	0,0017174
	relatívna chyba	-0,648 %	0,726 %	0,090 %	0,117 %	1,021 %
pokus 2 $F = 2,8019 \cdot 10^{-2}$	identifikovaná hodnota	7,5422	3,7455	0,60328	0,58146	0,0017207
	relatívna chyba	-0,865 %	1,230 %	0,296 %	0,321 %	1,220 %
pokus 3 $F = 3,0257 \cdot 10^{-2}$	identifikovaná hodnota	7,6412	3,6629	0,60331	0,58141	0,001689
	relatívna chyba	0,436 %	-1,003 %	0,300 %	0,312 %	-0,646 %
pokus 4 $F = 7,0252 \cdot 10^{-3}$	identifikovaná hodnota	7,6396	3,6753	0,60156	0,57959	0,0016894
	relatívna chyba	0,415 %	-0,668 %	0,009 %	-0,002 %	-0,622 %
pokus 5 $F = 1,6571 \cdot 10^{-1}$	identifikovaná hodnota	7,5454	3,7409	0,61008	0,58823	0,0017212
	relatívna chyba	-0,823 %	1,105 %	1,427 %	1,488 %	1,249 %

Tab.2 Porovnanie výsledkov identifikácie parametrov AM pri viacnásobnom spustení GA pre amplitúdu vstupného napätia 15 V a frekvenciu vstupného napätia 10 Hz s ich skutočnými hodnotami






Obr.7 Konvergenca GA pri identifikácii parametrov AM pri použití referenčného napätia s amplitúdou 15 V a frekvenciou 10 Hz




Obr.8 Porovnanie priebehov prúdu




Obr.9 Porovnanie priebehov prúdu

znázornená závislosť najlepšej hodnoty účelovej funkcie v aktuálnej generácii od počtu generácií pri jednotlivých pokusoch. Na obr. 8 a 9 je porovnanie priebehov prúdov modelov s identifikovanými a skutočnými parametrami AM pri prvom pokuse a na obr. 10 a 11 sú odchýlky týchto priebehov.

Na výsledky identifikácie parametrov reálneho zariadenia môže mať značný vplyv šum meracích kanálov a kvantovanie meraného



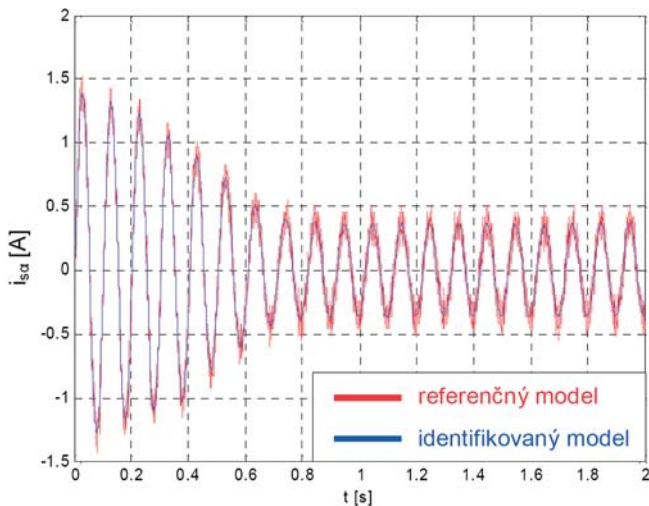
Obr.10 Odchýlka priebehov prúdu




Obr.11 Odchýlka priebehov prúdu

signálu A/D prevodom. V ďalšej časti bola overená schopnosť navrhnutého GA identifikovať parametre aj v prípade, ak sa použijú na identifikáciu zašumené a kvantované signály zložiek statorového prúdu. Na simulačnom modeli sa ako zdroj šumu použil biely šum so zosilnením $1 \cdot 10^{-6}$. Zároveň sa priebehy prúdov kvantovali 12-bitovým A/D prevodníkom. Z výsledkov identifikácie pri použití rôznych hodnôt amplitúdy a frekvencie vstupných napätí (tab. 3) možno vidieť, že šum a kvantovanie nemali významný vplyv na presnosť identifikácie parametrov v porovnaní s výsledkami z tab. 1. Na obr. 12 a 13 je porovnanie priebehov prúdov modelov s identifikovanými a skutočnými parametrami AM prvého pokusu, keď boli použité zašumené signály zložiek statorového prúdu.

Pri aplikácii algoritmu riadenia nám dostupné výpočtové prostriedky nie vždy umožňujú používať dostatočne nízku periódu vzorkovania. Preto je zaujímavé overenie, ako vplýva veľkosť zvolenej periódy vzorkovania na schopnosť identifikovať parametre AM s dostatočnou presnosťou. Pri frekvencii vstupného napätia 5 Hz dosiahneme nepresnosť identifikácie jednotlivých parametrov po 500 generáciách menšiu ako 1 % aj pri zvýšení periódy vzorkovania na hodnotu 2,5 ms. Pri frekvencii 10 Hz je potrebná na dosiahnutie takejto presnosti perióda vzorkovania 2 ms a pri frekvencii 20 Hz perióda 0,5 ms. Na dosiahnutie identifikácie s maximálnou 5 % nepresnosťou pri frekvencii 30 Hz sme museli periódu vzorkovania znížiť na 0,2 ms. Logicky teda vyplýva, čím vyššia frekvencia vstupného napätia sa použije, tým nižšia perióda



Obr.12 Porovnanie priebehov prúdu pri zašumení a kvantovaní referenčného signálu



Obr.13 Porovnanie priebehov prúdu pri zašumení a kvantovaní referenčného signálu

		R_s	R_r	L_s	L_m	J
	skutočná hodnota	7,608	3,7	0,6015	0,5796	0,0017
7,5 V, 5 Hz $F = 65,798$	identifikovaná hodnota	7,6558	3,7203	0,59966	0,57804	0,0016947
	relatívna chyba	0,628 %	0,548 %	-0,305 %	-0,270 %	-0,310 %
15 V, 10 Hz $F = 66,0976$	identifikovaná hodnota	7,5915	3,7133	0,5987	0,57701	0,0017053
	relatívna chyba	-0,217 %	0,359 %	-0,465 %	-0,446 %	0,312 %
30 V, 20 Hz $F = 66,0636$	identifikovaná hodnota	7,5184	3,7514	0,61277	0,59093	0,001728
	relatívna chyba	-1,178 %	1,389 %	1,873 %	1,955 %	1,644 %
45 V, 30 Hz $F = 97,9766$	identifikovaná hodnota	8,1638	3,3823	0,49211	0,47021	0,0015378
	relatívna chyba	7,364 %	-8,587 %	-18,19 %	-18,87 %	-9,543 %

Tab.3 Porovnanie výsledkov identifikácie parametrov AM genetickým algoritmom pri rôznych hodnotách amplitúdy a frekvencie vstupného napätia s ich skutočnými hodnotami pre zašumené signály so zosilnením $1 \cdot 10^{-6}$ zdroja šumu a s kvantovaním 12-bitovým A/D prevodom

		R_s	R_r	L_s	L_m	J
	skutočná hodnota	7,608	3,7	0,6015	0,5796	0,0017
7,5 V, 5 Hz $T_{vz} = 2,5 \text{ ms}$ $F = 1,3542 \cdot 10^{-3}$	identifikovaná hodnota	7,5974	3,684	0,59917	0,5772	0,0016948
	relatívna chyba	-0,139 %	-0,432 %	-0,388 %	-0,414 %	-0,305 %
15 V, 10 Hz $T_{vz} = 2 \text{ ms}$ $F = 1,5665 \cdot 10^{-3}$	identifikovaná hodnota	7,597	3,7073	0,60399	0,58205	0,0017019
	relatívna chyba	-0,145 %	0,197 %	0,414 %	0,423 %	0,109 %
30 V, 20 Hz $T_{vz} = 0,5 \text{ ms}$ $F = 8,2013 \cdot 10^{-3}$	identifikovaná hodnota	7,628	3,6868	0,59853	0,57663	0,0016941
	relatívna chyba	0,263 %	-0,356 %	-0,494 %	-0,512 %	-0,344 %
45 V, 30 Hz $T_{vz} = 0,2 \text{ ms}$ $F = 2,8285$	identifikovaná hodnota	7,8813	3,5953	0,59221	0,57026	0,0016332
	relatívna chyba	3,593 %	-2,829 %	-1,545 %	-1,612 %	-3,932 %

Tab.4 Výsledky identifikácie parametrov AM genetickým algoritmom pri použití rôznych hodnôt amplitúdy a frekvencie vstupného napätia a rôznych hodnôt periódy vzorkovania

da vzorkovania je potrebná. V tab. 4 sú uvedené výsledky identifikácie parametrov AM pri použití rôznych hodnôt periódy vzorkovania.

Záver

Výsledky nášho simulačného experimentu dokázali použiteľnosť genetických algoritmov na identifikáciu parametrov AM. Použitím účelovej funkcie, ktorá porovnáva priebehy zložiek prúdu, genetický algoritmus postupným generovaním riešení získava presnejšie hodnoty hľadaných parametrov. Nie vždy si však môžeme byť istí, že vyhovujúci výsledok dosiahneme po určitom počte generácií. Počet potrebných generácií na získanie dostatočne presného riešenia závisí od použitej frekvencie vstupného napätia. Preto môže byť výhodné ukončenie GA po dosiahnutí stanovenej

hodnoty kriteriálnej funkcie, prípadne v kombinácii s určením maximálneho počtu generácií, ak by mal GA problém dosiahnuť požadovanú fitness hodnotu. Zvyšovaním počtu generácií sa, samozrejme, predlžuje čas riešenia. Ten však môžeme znižovať využívaním apriórnych informácií, napríklad pri definovaní oblasti riešenia, aby algoritmus neprehľadával zbytočne veľký priestor. Vhodným nastavením genetického algoritmu a výberom referenčných signálov sme boli schopní dosiahnuť nepresnosť identifikácie menšiu ako 1 %.

Výhodou identifikácie parametrov AM pomocou genetického algoritmu je okrem jednoduchšej implementácie aj schopnosť rovnako presne identifikovať parametre pri zašumených a kvantovaných referenčných signáloch prúdu. To ich predurčuje na použitie pri identifikácii parametrov reálnych AM.

Parametre AM

$$\begin{array}{lll} P_n = 1,1 \text{ kW} & n = 2840 \text{ min}^{-1} & J = 0,0117 \text{ kg} \cdot \text{m}^{-2} \\ R_s = 7,608 \ \Omega & R_r = 3,700 \ \Omega & p' = 1 \\ L_s = 0,6015 \text{ H} & L_r = 0,6015 \text{ H} & L_m = 0,5796 \text{ H} \\ T_r = 0,1626 \text{ s} & \sigma = 0,0715 & \end{array}$$

Literatúra

- [1] CHUNG, P. Y., DÖLEN, M., LORENZ, R. D.: Parameter Identification for Induction Machines by Continuous Genetic Algorithms. ANNIE 2000 Conference, St. Louis, November 2000.
- [2] ŽALMAN, M.: Akčné členy. Vydavateľstvo STU, Bratislava, 2003.
- [3] KVASNIČKA, V., POSPÍCHAL, J., TIŇO, P.: Evolučné algoritmy. Vydavateľstvo STU, Bratislava, 2000.
- [4] SEKAJ, I.: Riešenie problémov pomocou genetických algoritmov. Automatizace, 47 (2004), č. 9, s. 552 – 554.
- [5] SEKAJ, I.: Evolučné výpočty a ich využitie v praxi. Vydavateľstvo IRIS, Bratislava, 2005.
- [6] URSEM, R. K.: Models for Evolutionary Algorithms and Their Application in System Identification and Control Optimization. PhD thesis, EVALife, Department of Computer Science, Univerzity of Aarhus, 2003.

Ing. Marián Jančovič
prof. Ing. Milan Žalman, PhD.

Slovenská technická univerzita
Fakulta elektrotechniky a informatiky
Katedra automatizácie a regulácie
Ilkovičova 3, 812 19 Bratislava
e-mail: milan.zalman@stuba.sk

