

Katarzyna RUTCZYŃSKA-WDOWIAK

POLITECHNIKA ŚWIĘTOKRZYSKA, SAM. ZAKŁAD SYSTEMÓW STEROWANIA I ZARZĄDZANIA

Modyfikacje algorytmu genetycznego w problemie identyfikacji modelu matematycznego silnika indukcyjnego

Dr inż. Katarzyna RUTCZYŃSKA-WDOWIAK

W 2000 r. rozpoczęła pracę w Samodzielnym Zakładzie Systemów Sterowania i Zarządzania na Wydziale Elektrotechniki, Automatyki i Informatyki Politechniki Świętokrzyskiej, początkowo na stanowisku asystenta, a następnie adiunkta (od 2005 r. do chwili obecnej). Obszar jej zainteresowań koncentruje się na problematyce zastosowania algorytmów genetycznych i strategii ewolucyjnych w identyfikacji obiektów dynamicznych.



e-mail: karut@tu.kielce.pl

Streszczenie

Praca przedstawia problem parametrycznej identyfikacji modelu matematycznego silnika indukcyjnego z zastosowaniem algorytmów genetycznych. Parametry modelu matematycznego zostały wyznaczone w rezultacie minimalizacji błędu średniokwadratowego amplitudy prądu stojana i prędkości kątowej. Praca opisuje problem identyfikacji, reprezentację osobników i operatory genetyczne, takie jak: krzyżowanie, mutacja i selekcja turniejowa z częściową wymianą populacji. Algorytmy genetyczne były analizowane z uwagi na zbieżność i dokładność procesu identyfikacji oraz czas analizy numerycznej.

Słowa kluczowe: algorytm genetyczny, identyfikacja, dynamika, silnik indukcyjny

Modifications of genetic algorithm in identification problem of induction motor

Abstract

This paper presents the problem of parametric identification of induction motor mathematical model with the use of genetic algorithms. The parameters of induction motor mathematical model were determined as a result of mean-square error minimisation of stator current and angular velocity. The work describes the problem of identification, the representation of individuals and the genetic operators, such as: crossover, mutation and the tournament selection with steady state. The genetic algorithms were analysed with regard to convergence and accuracy of the identification process and the time of numerical analysis.

Keywords: genetic algorithm, identification problem, dynamics, induction motor

1. Wstęp

Model matematyczny silnika indukcyjnego, uwzględniający dynamikę stanu elektromagnetycznego i dynamikę prędkości kątowej wirnika, jest złożonym układem nieliniowych równań różniczkowych [7]. Taka postać modelu matematycznego znacznie utrudnia jego identyfikację. Problemy dotyczące identyfikacji parametrycznej silnika indukcyjnego są więc zagadnieniami trudnymi, ale cieszącymi się stałym zainteresowaniem wielu badaczy [5, 6, 10]. W obecnych czasach, oprócz powszechnie znanych i stosowanych metod klasycznych [11], coraz częściej poszukuje się nowych metod, które umożliwią przeprowadzenie efektywnej i skutecznej identyfikacji. Wśród nich można wyróżnić także metody zaliczane do tzw. sztucznej inteligencji, a więc m.in. algorytmy genetyczne. Algorytm genetyczny (AG) jest nowoczesną, komputerową metodą inspirowaną kilkoma zasadami zaczerpniętymi z teorii ewolucji, tj. prawami naturalnej selekcji

i genetyki, opartymi na regule przeżycia osobników najsilniejszych [2, 4, 9].

Wybór algorytmu genetycznego do rozwiązania problemu identyfikacji wynika z faktu, że algorytmy te zapewniają w stosunku do innych powszechniej stosowanych metod klasycznych znacznie większe prawdopodobieństwo wyznaczenia minimum globalnego przyjętego wskaźnika jakości [8, 12].

Jednym z podstawowych problemów dotyczących rozwiązania zagadnienia identyfikacji jest dobór odpowiedniego algorytmu genetycznego. Identyfikacja modelu matematycznego silnika indukcyjnego jest skomplikowanym zagadnieniem, dlatego tak należy wybrać algorytm genetyczny oraz zestaw jego parametrów, aby z jednej strony otrzymać dobrą zbieżność analizowanego procesu, natomiast z drugiej, aby czas identyfikacji był możliwie jak najkrótszy. Niewłaściwy dobór algorytmu genetycznego lub jego parametrów może być przyczyną przedwczesnej zbieżności algorytmu albo znacznie wydłużyć czas analizowanego procesu identyfikacji.

W pracy analizowano wpływ kodowania parametrów zadania, przyjętej metody selekcji, krzyżowania oraz mutacji na wyniki identyfikacji oraz wymagany nakład obliczeń. Szereg wprowadzonych w algorytmie genetycznym modyfikacji z uwzględnieniem pomocniczych mechanizmów, wpływających na poprawę jego działania, a także różnych sposobów zatrzymania AG pozwalała zdaniem autora na wybranie algorytmu genetycznego zapewniającego dobrą zbieżność i dokładność procesu przy jak najmniejszym koszcie obliczeń.

W niniejszej pracy rozważano problem identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego w warunkach off-line, przy użyciu wybranych algorytmów genetycznych. Identyfikacja parametrów modelu matematycznego silnika indukcyjnego w czasie rzeczywistym za pomocą ww. metod nie jest w zasadzie możliwa, ze względu na bardzo duży nakład obliczeń [1, 3].

2. Model matematyczny silnika indukcyjnego

Opis matematyczny silnika indukcyjnego jest złożonym układem nieliniowych równań różniczkowych, przedstawiających równanie ruchu obrotowego wirnika oraz odpowiednie zależności między napięciami, prądami i strumieniami magnetycznymi. Dodatkowe uwzględnienie zjawisk, takich jak: anizotropia, histereza, nasylenie obwodu magnetycznego, asymetria w rozłożeniu uzwojeń, zjawiska wypierania prądu w przewodach uzwojeń, prowadzi do skomplikowanych równań o parametrach rozłożonych, które są mało przydatne w analizie i syntezie układów napędowych. Z uwagi na to, zgodnie z literaturą [7] stosuje się pewne założenia upraszczające, dla których silnik indukcyjny stanowi obiekt sterowania o parametrach skupionych, co w opisie matematycznym wyraża się w postaci równań różniczkowych zwyczajnych o stałych współczynnikach [7, 10, 11].

Równania silnika są z reguły przedstawiane w prostokątnym układzie współrzędnych, w którym opisuje się związki zachodzące między odpowiednimi składowymi wektorów przestrzennych prądu, napięcia i strumienia. Model matematyczny silnika indukcyjnego sformułowany w wirującym układzie współrzędnych $d-q$, zorientowanym zgodnie z wektorem v_s napięcia stojana, ma następującą postać [7]:

$$\begin{aligned}
\frac{d}{dt}\phi_d(t) &= \phi_q(t)\omega_s(t) - R_s I_d(t) + v(t) \\
\frac{d}{dt}\phi_q(t) &= -\phi_d(t)\omega_s(t) - R_s I_q(t) \\
\frac{d}{dt}I_d(t) &= a_1\phi_d(t) + a_3\phi_q(t)\omega_e(t) - a_2 I_d(t) + I_q(t)\omega_s(t) + \\
&\quad - I_q(t)\omega_e(t) + a_3 v(t) \\
\frac{d}{dt}I_q(t) &= -a_3\phi_d(t)\omega_e(t) + a_1\phi_q(t) - I_d(t)\omega_s(t) + \\
&\quad + I_d(t)\omega_e(t) - a_2 I_q(t) \\
\frac{d}{dt}\omega_e(t) &= \frac{3p^2}{2J}(\phi_d(t)I_q(t) - \phi_q(t)I_d(t)) - \frac{p}{J}M_o(t)
\end{aligned} \quad (1)$$

przy czym:

$$a_1 = \frac{R_r}{\sigma L_s L_r}, \quad a_2 = \frac{R_s}{\sigma L_s} + \frac{R_r}{\sigma L_r}, \quad a_3 = \frac{1}{\sigma L_s}, \quad \sigma = \frac{L_s L_r - L_m^2}{L_s L_r} \quad (2)$$

gdzie: I_d , I_q i ϕ_d , ϕ_q – składowe wektora prądu i strumienia stojana, ω_s – pulsacja synchroniczna stojana, $\omega_e = p\omega$ – elektryczna prędkość kątowna, R_s i L_s – rezystancja i indukcyjność stojana, R_r i L_r – rezystancja i indukcyjność wirnika, L_m – indukcyjność główna, p – liczba par biegunów, J – moment bezwładności, M_o – moment obciążenia, v – moduł wektora napięcia stojana, σ – wypadkowy współczynnik rozproszenia [7, 11].

W wirującym układzie współrzędnych zorientowanym zgodnie z wektorem napięcia stojana sygnałami wejściowymi silnika są amplituda v wektora napięcia stojana v_s i pulsacja synchroniczna ω_s , natomiast sygnałami wyjściowymi – prędkość kątowna ω i amplituda I wektora prądu stojana [7, 8, 11, 12].

3. Identyfikacja modelu matematycznego silnika indukcyjnego

Identyfikacji modelu matematycznego silnika (1)-(2) dokonano na podstawie danych pomiarowych odpowiedzi czasowych amplitudy prądów fazowych stojana oraz prędkości kątownej, zarejestrowanych podczas rozruchu silnika. Do dalszych rozważań przyjęto wskaźnik jakości identyfikacji Q w postaci błędu średniokwadratowego amplitudy prądu stojana I oraz prędkości kątownej ω

$$Q = \frac{1}{N} \left(\sum_{i=1}^N (\omega(i) - \hat{\omega}(i))^2 + W \sum_{i=1}^N (I(i) - \hat{I}(i))^2 \right) \quad (3)$$

gdzie: N – liczba pomiarów, W – współczynnik wagowy, wyznaczony eksperymentalnie [11], w celu zachowania kompromisu pomiędzy wartością sumy kwadratów błędów prędkości kątownej ω i błędów prądu stojana I , $\hat{\cdot}$ – rozwiązanie modelu matematycznego silnika.

Celem pracy jest propozycja struktury i parametrów algorytmu genetycznego zapewniającego dobrą zbieżność i dokładność identyfikacji oraz stosunkowo krótki czas analizowanego procesu.

Zastosowany w pierwszym etapie badań algorytm genetyczny opiera się, podobnie jak klasyczny AG, na binarnej reprezentacji chromosomów oraz na współdziałaniu trzech podstawowych operacji genetycznych: selekcji, krzyżowania i mutacji z tą różnicą, że są one wykonywane jedynie na wybranej grupie osobników. Oznacza to, że ustalona część populacji przechodzi do następnego pokolenia bez żadnych zmian. Biorąc pod uwagę specyfikę takiego algorytmu, nacisk położono na dobór odpowiedniej metody selekcji. Z uwagi na występowanie niestabilności rozwiązań modelu matematycznego silnika, algorytm genetyczny zapewnia stabilność populacji. Długość każdego z chromosomów wyznaczono w oparciu o literaturę [2, 4]. Przestrzeń poszukiwań rozwiązania określana jest dla każdego identyfikowanego parametru

oddzielnie, a funkcja przystosowania – zdefiniowana na podstawie [2] – przyjmuje wartości nieujemne. W procesie selekcji zastosowano metodę turniejową z tzw. częściową wymianą populacji (według [4] ang. *tournament selection with steady-state*), ponieważ jak wykazano w publikacjach [4, 8, 13] na przykładach z dziedziny badań operacyjnych, a także prowadzonych przez autora doświadczeń w zakresie identyfikacji, połączenie tego typu umożliwiają uzyskanie bardzo dobrych rezultatów. W wyniku krzyżowania (krzyżowanie jednopunktowe) i mutacji (losowa negacja bitu) powstaje dwóch potomków, przy czym tylko jeden z nich zostaje dołączony do populacji. Nowopowstały potomek „zawiera się” w przedziałach określoności identyfikowanych parametrów. W analizowanym problemie identyfikacji rozważano następujące strategie zastępowania:

- losowo wybrany potomek (bez względu na wartość funkcji przystosowania) zastępuje losowego osobnika w populacji,
- losowo wybrany potomek zastępuje najgorszego osobnika (o najmniejszej wartości funkcji przystosowania),
- lepszy potomek zastępuje najgorszego w danej populacji.

Po wstępnych próbach wybrano najlepszy zdaniem autora wariant, w którym lepszy z potomków zastępuje najslabszego osobnika w populacji. Bardzo wysoka wartość prawdopodobieństwa krzyżowania ($p_k = 1$) wynika ze specyfiki prezentowanego algorytmu, w którym w pojedynczej iteracji do operacji krzyżowania wytypowana zostaje tylko jedna para osobników rodzicielskich. Algorytm genetyczny ochrania najlepszego osobnika w populacji. Dzięki takiemu założeniu możliwe jest zakończenie procesu, gdy po ustalonej liczbie iteracji najlepszy osobnik z bieżącego pokolenia nie ulega już poprawie. Pierwszy z warunków zatrzymania działania AG, oznaczonego dla ułatwienia skrótem AG1, dotyczy przyjętej na początku uruchamiania procedury identyfikacji liczby iteracji. Otrzymanym rozwiązaniem jest chromosom o minimalnej wartości wskaźnika Q w ostatnim pokoleniu.

Aby określić wpływ operatorów genetycznych na zbieżność i dokładność procesu identyfikacji konieczne jest uwzględnienie specyficznego mechanizmu działania ww. AG, w którym w operacji krzyżowania uczestniczy tylko pojedyncza para osobników. Z uwagi na powyższe dobiera się jedynie odpowiednią wartość prawdopodobieństwa mutacji p_m . W celu ustalenia odpowiedniego poziomu prawdopodobieństwa mutacji badania realizowano dla: $p_m \in [0,01; 0,1]$ z krokiem $5 \cdot 10^{-3}$ oraz $p_m = 0$. Ze względu na stochastyczny charakter AG, w przeprowadzanych badaniach, zwykle podaje się wynik średni z kilku (w odniesieniu do podanej literatury najczęściej z 10-ciu) niezależnych od siebie doświadczeń, ewentualnie z uwzględnieniem odchylenia standardowego.

Identyfikację modelu matematycznego silnika przeprowadzono na podstawie przetwarzania danych z symulacji komputerowej i z pomiarów laboratoryjnych odpowiedzi czasowej prędkości kątownej ω oraz prądu stojana I , na skokową zmianę pulsacji synchronicznej $\omega_s = 314 \cdot 1(t)$ rad/s i napięcia stojana $v = 311 \cdot 1(t)$ V. W symulacji procesu identyfikacji (tabela 1 oraz 3) przyjęto następujące wartości parametrów modelu matematycznego silnika: $a_1 = 521,4$, $a_2 = 280,1$, $a_3 = 54,2$, $J = 0,04$ kgm² i $R_s = 2,95$ Ω oraz liczbę pomiarów $N = 1000$, oczekiwano uzyskanie zadanych parametrów modelu matematycznego z określoną dokładnością przy wartości wskaźnika jakości Q bliskiej zeru, natomiast w tabelach 2 oraz 4 przedstawiono wyniki identyfikacji eksperymentalnej w oparciu o dane pomiarowe (na obiekcie rzeczywistym), stąd wynikają różnice w uzyskanych wartościach wskaźnika jakości Q .

Zgodność trajektorii czasowych prądu i prędkości kątownej silnika oraz jego modelu matematycznego oceniano za pomocą współczynników korelacji wielowymiarowej R (wielkość unormowana, przyjmująca wartości w przedziale $0 \leq R \leq 1$) odpowiednio R_I – dla przebiegu prądu oraz R_ω – dla przebiegu prędkości.

Tabela 1 przedstawia wartości średnie otrzymanych rezultatów z 10-ciu doświadczeń symulacyjnych, zrealizowanych przy użyciu algorytmu genetycznego AG1. Identyfikowano parametry modelu matematycznego, tj.: a_1 , a_2 i a_3 . Przyjęto dokładność uzyskania rozwiązania 0,001 oraz kryterium zatrzymania AG na poziomie ustalonej na początku uruchomienia procedury liczby iteracji.

Tab. 1. Dobór prawdopodobieństwa mutacji p_m (wyniki symulacji procesu identyfikacji z zastosowaniem algorytmu genetycznego AG1)
Tab. 1. The choice of probability of mutation (the results of simulation of the identification process with the use of genetic algorithm AG1)

Parametr p_m	Wyniki średnie						
	Wartości identyfikowanych parametrów			Wskaźnik jakości Q	Czas procesu [min]	Współczynnik korelacji	
	a_1	a_2	a_3			R_{\square}	R_I
0	535,923	280,982	54,426	0,650	58	1,000	1,000
0,01	516,920	279,102	53,990	0,321	61	1,000	1,000
0,06	518,515	279,325	54,063	0,129	55	1,000	1,000
0,1	518,246	279,343	54,072	0,130	56	1,000	1,000

Przedstawione zestawienie wyników symulacji procesu identyfikacji wskazuje, że w przypadku algorytmu genetycznego AG1 operacja mutacji jest niezbędna, ponieważ wprowadza pewną różnorodność w populacji, co prowadzi do poprawy działania AG. Lepsze rezultaty (z uwagi na wartość wskaźnika Q) można więc uzyskać zakładając większe prawdopodobieństwo p_m . W przeprowadzonej serii badań wyodrębniono dwie wartości parametru p_m , dla których AG1 zdaniem autora osiąga najlepsze wyniki, a mianowicie: 0,06 oraz 0,1. Do realizacji kolejnych doświadczeń wybrano pierwszą z wymienionych wartości, biorąc pod uwagę otrzymaną najmniejszą wartość wskaźnika jakości identyfikacji Q .

W niektórych przypadkach, nawet przy stałym rozmiarze populacji, dokładności uzyskania rozwiązania oraz przyjętej identycznej przestrzeni poszukiwań, trudno jest określić odpowiednią liczbę iteracji (warunek zatrzymania AG), tak aby otrzymać dobre rezultaty możliwie jak najmniejszym kosztem obliczeń. Dlatego wygodniej jest zastosować dodatkowe kryterium stopu, które pozwoli na wcześniejsze zakończenie procesu identyfikacji. Z uwagi na to, w tabeli 2 przedstawiającej wyniki identyfikacji eksperymentalnej, przyjęto drugi z rozważanych warunków zatrzymania, który umożliwia zmniejszenie nakładu obliczeń i skrócenie czasu procesu, w porównaniu do przyjętej liczby iteracji jako kryterium zatrzymania AG.

Tab. 2. Wpływ rozmiaru populacji na czas procesu identyfikacji eksperymentalnej z zastosowaniem algorytmu genetycznego AG1

Tab. 2. The influence of population size on time of identification process with the use of genetic algorithm AG1

Rozmiar populacji	Wartości średnie parametrów otrzymanych w procesie identyfikacji			Średni czas procesu [min]	Średni wskaźnik jakości Q	Średnia liczba iteracji	Wartość średnia współczynników korelacji	
	a_1	a_2	a_3				R_{\square}	R_I
30	548,617	287,094	55,072	58	44,584	335	1,000	0,991
40	551,027	286,721	54,493	86	45,597	384	1,000	0,991
50	535,892	287,485	55,551	103	44,663	419	1,000	0,991
60	541,553	288,889	54,991	133	45,085	431	1,000	0,991

Tabela 2 przedstawia analizę wpływu rozmiaru populacji ($r_p = 30 \div 60$) na wyniki identyfikacji eksperymentalnej z wykorzystaniem algorytmu AG1 z warunkiem zatrzymania określonym poprawą wartości wskaźnika jakości Q najlepszego osobnika w kolejnych 50-ciu populacjach (zadana liczba iteracji, jaką może maksymalnie wykonać algorytm genetyczny wynosi 600). Przeprowadzone badania dowodzą, że w przypadku zastosowania algorytmu genetycznego AG1 z wyżej sprecyzowanym kryterium zatrzymania, zwiększenie rozmiaru populacji proporcjonalnie wydłuża czas identyfikacji, ponieważ algorytm wymaga większego nakładu obliczeń. Wielkość populacji wykorzystanych w procesie identyfikacji nie wpływa natomiast na zbieżność i dokładność procesu.

Ze względu na złożoność analizowanego problemu identyfikacji parametrycznej, wykorzystanie kodowania binarnego, które najlepiej wyraża specyfikę działania AG, wymaga znacznego nakładu obliczeń, dlatego w kolejnym etapie proponowanych zmian zastąpiono kodowanie binarne tzw. kodowaniem zmiennopozycyjnym, które z uwagi na czas obliczeń jest zdecydowanie szybsze. Operatory genetyczne zostały zdefiniowane w taki sposób, aby zachować ograniczenia narzucone na identyfikowane parametry. Selekcję zrealizowano w oparciu o metodę turniejową z częściową wymianą populacji przy uwzględnieniu warunku, że nowopowstały potomek zastępuje osobnika najgorszego w populacji. W operacji krzyżowania zamiast krzyżowania jednopunktowego, zastosowano jednorodnie krzyżowanie arytmetyczne [4], zakładając stałą dla całego przebiegu genetycznego wartość parametru α , wynoszącą 0,5 (w literaturze cytowanej w [4] określane również dla ww. wartości α – gwarantowanym średnim krzyżowaniem lub po prostu krzyżowaniem arytmetycznym). Takie podejście umożliwiło zredukowanie liczby narzuconych na algorytm warunków, ponieważ w wyniku zadziałania operatora krzyżowania powstaje tylko jeden potomek, który następnie jest poddawany operacji mutacji. Mutacja w omawianej implementacji AG, nazywana według [4] mianem mutacji równomiernej, polega na zastąpieniu wytypowanego w sposób losowy elementu wektora, liczbą wylosowaną z zakresu określoności danego parametru. Przyjęto stałe tempo krzyżowania i mutacji, odpowiednio $p_k = 1$ oraz $p_m = 0,01 \div 0,1$. Algorytm genetyczny, oznaczony jako AG2, ochrania najlepszego osobnika w bieżącym pokoleniu oraz gwarantuje stabilność całej populacji. Przyjęto, że algorytm AG2 kończy obliczenia, kiedy po określonej liczbie iteracji nie obserwuje się poprawy otrzymanych wyników (w kolejnych 50-ciu pokoleniach nie ma poprawy najmniejszej wartości wskaźnika jakości Q lub gdy liczba iteracji osiągnie założoną wcześniej wartość). W tabeli 3 analizowano wpływ operacji mutacji na przebieg algorytmu genetycznego AG2 (zwiększono przestrzeń poszukiwań AG w porównaniu do tabeli 1). Są to wartości średnie z 10-ciu doświadczeń symulacyjnych.

Tab. 3. Dobór prawdopodobieństwa mutacji p_m (wyniki symulacji procesu identyfikacji z zastosowaniem algorytmu genetycznego AG2)

Tab. 3. The choice of probability of mutation (the results of simulation of the identification process with the use of genetic algorithm AG2)

Przestrzeń poszukiwań	Parametr p_m	Wartości średnie identyfikowanych parametrów			Średni wskaźnik jakości Q
		a_1	a_2	a_3	
$a_1 = [391; 652]$ $a_2 = [210; 350]$ $a_3 = [41; 68]$	0	531,341	278,640	53,634	1,396
	0,01	480,954	277,825	53,854	0,488
	0,06	522,327	279,503	54,043	0,147
	0,1	498,075	278,500	53,968	0,227

Analizując wyniki badań przedstawione w tabeli 3 można wywnioskować, że w przypadku algorytmu genetycznego AG2, podobnie jak w przypadku algorytmu genetycznego AG1, należy dobierać stosunkowo wysokie prawdopodobieństwo mutacji. Najlepsze rezultaty uzyskano, dla prawdopodobieństwa mutacji $p_m = 0,06$, w związku z czym uznano tę wartość za najlepszą i wykorzystano w dalszych badaniach. W przypadku braku mutacji, co ma miejsce, gdy $p_m = 0$, otrzymano najgorsze rezultaty ze wszystkich rozpatrywanych. Świadczy to o konieczności występowania mutacji w algorytmie genetycznym AG2.

W tabeli 4 analizowano w jakim stopniu zastosowana w algorytmie genetycznym reprezentacja osobników oraz rodzaj krzyżowania wpływa na wartości parametrów modelu matematycznego silnika, tj.: a_1 , a_2 i a_3 wyznaczanych w procesie identyfikacji eksperymentalnej. Wyniki otrzymane z 10-ciu przebiegów algorytmu genetycznego z reprezentacją zmiennopozycyjną i krzyżowaniem arytmetycznym AG2 charakteryzują się znacznie mniejszym odchyleniem standardowym, w porównaniu do uzyskanych przy użyciu algorytmu genetycznego z kodowaniem binarnym i operatorem krzyżowania jednopunktowego AG1. Porównując efektywność ww. algorytmów można zauważyć, że największe wartości odchyżeń standardowych dotyczą liczby iteracji oraz czasu procesu identyfikacji z zastosowaniem algorytmu AG1. Zmiana reprezentacji osobników oraz operatora krzyżowania wpłynęła również na poprawę zbieżności i dokładności analizowanego procesu identyfikacji, o czym świadczą pokazane wartości średnie wyników.

Tab. 4. Wpływ reprezentacji osobników i operatora krzyżowania na wyniki procesu identyfikacji eksperymentalnej

Tab. 4. The influence of representation of individuals and crossover operator on results of experimental identification process

AG	Wynik średni [Odchylenie standardowe]					Współczynnik korelacji		
	a_1	a_2	a_3	Q	Czas [min]	Liczba iteracji	R_{\square}	R_I
AG1	567,5422 [26,9249]	290,2811 [3,5391]	55,6847 [0,9014]	45,2944 [2,1379]	95 [22]	445 [116]	0,9995 [0,0006]	0,9915 [0,0006]
AG2	543,3269 [22,1039]	287,2321 [2,5351]	55,3240 [0,5010]	44,9895 [1,1582]	17 [3]	493 [86]	0,9998 [0,0001]	0,9912 [0,0006]

4. Podsumowanie

W pracy analizowano wpływ zastosowanego kodowania, przyjętej metody selekcji i zastępowania osobników, operatora krzyżowania i mutacji, a także warunku zatrzymania AG na wyniki identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego. Na podstawie przeprowadzonych badań sformułowano następujące wnioski. Zastosowanie w procesie identyfikacji algorytmu genetycznego opartego na ciągach zerowejedynkowych, w którym selekcję wykonywaną na wszystkich osobnikach zastąpiono selekcją turniejową z częściową wymianą populacji, a także wprowadzenie kilku mechanizmów zastępowania osobników pozwoliło na uzyskanie dobrej zbieżności i dokładności identyfikacji, jednak ze względu na niezbędne przeliczenia związane z reprezentacją binarną analizowany proces identyfikacji można zaliczyć do grupy procesów czasochłonnych. Istotne korzyści,

w powiązaniu z powyżej wymienionymi modyfikacjami, przyniosła zmiana reprezentacji osobników z binarnej na zmiennopozycyjną, dostosowanie operatora mutacji oraz wprowadzenie krzyżowania arytmetycznego, co dodatkowo zmniejszyło koszt obliczeń. Badania wykazały, że algorytm genetyczny oparty na wektorach zmiennopozycyjnych oraz krzyżowaniu arytmetycznym i mutacji równomiernej zbiegał się znacznie szybciej do oczekiwanej wartości minimum globalnego przyjętego wskaźnika jakości. Z uwagi na to może być on stosowany nawet dla większych populacji. Wykazano, że skuteczność i efektywność działania wykorzystanych algorytmów genetycznych zależy od odpowiedniego doboru prawdopodobieństwa mutacji. Ze względu na specyfikę działania tych algorytmów przy zadanym, bardzo wysokim prawdopodobieństwie krzyżowania (wartość wynikająca z przyjętej specyfiki AG), należy dobierać dość wysokie prawdopodobieństwo wystąpienia mutacji. Natomiast brak mutacji prowadzi do pogorszenia zbieżności i dokładności procesu identyfikacji.

5. Literatura

- [1] Alonge F., D'Ippolito F., Ferrante G., Raimondi F. M.: Parameter Identification of Induction Motor Model Using Genetic Algorithms. IEE Proceedings Control Theory and Applications Vol. 145 No. 6 1998 pp. 587-593.
- [2] Goldberg D. E.: Algorytmy genetyczne i ich zastosowania. WNT Warszawa 1995.
- [3] Man K. F., Tang K. S., Kwong S.: Genetic Algorithms: Concepts and Applications. IEEE Trans. on Industrial Electronics Vol. 43 No. 5 1996 pp. 519-534.
- [4] Michalewicz Zb.: Algorytmy genetyczne + struktury danych = programy ewolucyjne. WNT Warszawa 1999.
- [5] Moons Ch., Moor B.: Parameter Identification of Induction Motor Drives. Automatica Vol. 31 No. 8 1995 pp. 1137-1147.
- [6] Orłowska-Kowalska T., Bos A.: Zagadnienia wyznaczania parametrów schematu zastępczego silnika indukcyjnego w stanie nieruchomym. Przegląd Elektrotechniczny 9/2001 str. 222-226.
- [7] Pełczewski Wł., Krynke M.: Metoda zmiennych stanu w analizie dynamiki układów napędowych. WNT Warszawa 1984.
- [8] Rutczyńska-Wdowiak K.: Identification of induction motor mathematical model with the use of genetic algorithms. Proc. of the International Conference Intelligent Control Systems Brno 2005 pp. 90-95.
- [9] Rutkowska D., Piliński M., Rutkowski L.: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. PWN Warszawa 1997.
- [10] Söderström T., Stoica P.: Identyfikacja systemów. PWN Warszawa 1997.
- [11] Stefański T.: Synteza adaptacyjnych algorytmów sterowania momentem falownikowego napędu samochodu elektrycznego z silnikiem indukcyjnym. Rozprawa habilitacyjna Z. N. PŚk. nr 4 Kielce 1995.
- [12] Stefański T., Rutczyńska-Wdowiak K.: Regulacja prędkości kątowej masy obciążenia silnika indukcyjnego. XII Konferencja Naukowa SEMTRAK 2006 str. 327-332.
- [13] Vas P.: Artificial-Intelligence-Based Electrical Machines and Drives. Oxford University Press New York 1999.