

doi:10.15199/48.2016.12.70

Dobór kryterium zatrzymania algorytmu genetycznego na przykładzie identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego

Streszczenie. Praca przedstawia rezultaty wykorzystania algorytmu genetycznego (AG) w problemie identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego. Badania koncentrowały się na doborze kryterium zatrzymania algorytmu genetycznego, biorąc pod uwagę zbieżność i dokładność analizowanego procesu, jak również czas wymaganej analizy numerycznej. Wybór kryterium stopu jest kwestią bardzo ważną, ponieważ nieodpowiednio dobrane może niepotrzebnie wydłużyć czas procesu lub być przyczyną przedwczesnej zbieżności AG.

Abstract. This paper presents the results of genetic algorithm (GA) application in parametric identification of induction motor mathematical model problem. The research was concentrated on the selection of stop criterion genetic algorithm with regard to convergence and accuracy of analyzed process, as well as the time of required numerical analysis. Selecting of stop criterion is a very important issue, because improperly selected may needlessly prolong the time of process or be the cause of premature convergence of the GA. (The selection of stop criterion of genetic algorithm for example the parametric identification of induction motor mathematical model).

Słowa kluczowe: algorytm genetyczny, kryterium stopu, silnik indukcyjny, identyfikacja, modelowanie matematyczne.

Keywords: genetic algorithm, stop criterion, induction motor, identification, mathematical modeling.

Wprowadzenie

W ogólnym ujęciu modelowanie matematyczne silników indukcyjnych jedno- oraz dwukłatkowych można podzielić na trzy podstawowe etapy, takie jak: określenie równań różniczkowych lub algebraicznych nazywanych modelem matematycznym, wyznaczenie wartości współczynników tych równań (parametrów modelu matematycznego silnika) i weryfikację otrzymanych wyników [2, 17, 20, 24, 25]. Najczęściej wykorzystywane są klasyczne modele matematyczne silników indukcyjnych, które są sformułowane w postaci układu nieliniowych równań różniczkowych zwyczajnych, gdzie klatka wirnika i obwód stojana są traktowane jako obwody o parametrach skupionych [16, 20, 24]. Złożona postać modelu matematycznego silnika ma znaczący wpływ na przebieg i wyniki procesu identyfikacji. Obecnie stosowane algorytmy komputerowe zapewniają przeprowadzenie skutecznej identyfikacji, pod warunkiem odpowiednio dobranego modelu matematycznego, postaci wskaźnika jakości, a także metody jego minimalizacji. W wielu pracach do minimalizacji wskaźnika jakości identyfikacji w warunkach *off-line* często wykorzystywane są klasyczne metody optymalizacji statycznej [24], na przykład metoda Boxa, czy Simplex, a współcześnie coraz bardziej popularne metody sztucznej inteligencji [15, 17, 20]. Zainteresowanie, które wzbudzają metody sztucznej inteligencji w problemach identyfikacji wynika z ich skuteczności w innych dziedzinach techniki, czego liczne dowody można znaleźć w literaturze [1, 3, 4, 6, 7, 8, 9, 10, 11, 12, 13]. Badania prowadzone przez autora z zakresu stosowania wybranych metod sztucznej inteligencji, tj. algorytmów genetycznych, ewolucyjnych oraz hybrydowych w zagadnieniach optymalizacji [18, 19, 21] wskazują istotny kierunek do dalszej analizy skuteczności i efektywności działania tych algorytmów. A mianowicie ważne jest nie tylko odpowiednie dobranie struktury algorytmu genetycznego (AG), czy ewolucyjnego (AE), rozumianej jako określenie poszczególnych elementów algorytmu, ale także zestawu jego parametrów kontrolnych zależnych od typu i częstości zachodzących w nim operacji genetycznych [5, 14, 22, 23]. Ostatnim, równie ważnym krokiem jest odpowiednie zdefiniowanie warunku stopu algorytmu, ponieważ niewłaściwy wybór, z jednej strony jest powodem niepotrzebnego wydłużenia czasu rozważanego procesu,

natomiast z drugiej może być przyczyną przedwczesnej zbieżności algorytmu. Omawiane algorytmy w literaturze [5, 14, 22] zaliczane są do metod czasochłonnych i wymagających znacznej mocy obliczeniowej (porównując je np. z metodami klasycznymi), dlatego dobór warunku zatrzymania algorytmu jest sprawą kluczową. Przygotowanie AG, czy AE do implementacji wymaga wiedzy oraz czasu, ale rezultatem tego działania jest uzyskanie skutecznego i efektywnego narzędzia do rozwiązywania różnych zadań, w tym identyfikacji parametrycznej.

W niniejszej pracy przedstawiono problem doboru odpowiedniego kryterium zatrzymania algorytmu genetycznego na przykładzie identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego. Analizowano wpływ zastosowanego kryterium stopu na zbieżność i dokładność procesu identyfikacji oraz czas obliczeń numerycznych. Parametry modelu matematycznego silnika indukcyjnego identyfikowano na podstawie odpowiedzi czasowych prędkości kątowej i prądu stojana silnika oraz rozwiązania modelu, na podstawie minimalizacji przyjętego wskaźnika jakości z zastosowaniem algorytmu genetycznego. W procesie identyfikacji parametrycznej wykorzystano jeden z powszechnie znanych modeli matematycznych silnika, tj. sformułowany w wirującym układzie współrzędnych zorientowanym zgodnie z wektorem napięcia stojana [16, 20]. Identyfikację eksperymentalną zrealizowano w warunkach zbliżonych do warunków pracy silnika. Badania eksperymentalne wykonano dla silnika indukcyjnego małej mocy.

Sformułowanie problemu identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego

Równania silnika indukcyjnego są najczęściej prezentowane w prostokątnym układzie współrzędnych, w którym podaje się zależności zachodzące między odpowiednimi składowymi wektorów przestrzennych prądu, napięcia i strumienia. W literaturze [16, 24] najczęściej są stosowane dwa podstawowe układy współrzędnych, tj. stacjonarny (nieruchomy) oraz wirujący zgodnie z wektorem napięcia, prądu lub strumienia stojana.

W pracy zastosowano znany z literatury [16] model matematyczny silnika indukcyjnego sformułowany w wirującym układzie współrzędnych d - q , zorientowanym zgodnie z wektorem napięcia stojana wyrażony za pomocą następujących zależności [16, 20, 24]:

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

oraz

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

gdzie: I_d , I_q – składowe wektora prądu stojana, ϕ_d , ϕ_q – składowe wektora strumienia stojana, R_s i R_r – rezystancja odpowiednio stojana i wirnika, L_s , L_r oraz L_m – indukcyjność odpowiednio stojana, wirnika oraz główna, ω – mechaniczna prędkość kątowna, ω_e – elektryczna prędkość kątowna, gdzie $\omega_e = p\omega$, p – liczba par biegunów, ω_s – pulsacja synchroniczna stojana, v – moduł wektora napięcia stojana, J – moment bezwładności, M_o – moment obciążenia, σ – wypadkowy współczynnik rozproszenia [16].

Identyfikowane parametry modelu matematycznego silnika indukcyjnego (1)-(2) wyznaczono w oparciu o minimalizację wskaźnika jakości stanowiącego błąd średniokwadratowy amplitudy prądu stojana oraz prędkości kątownej silnika i modelu. W badaniach przyjęto wskaźnik jakości identyfikacji (3), ponieważ w pracy [17] wykazano, że z uwagi na zbieżność i dokładność analizowanego problemu identyfikacji pozwala on na otrzymanie najlepszych wyników

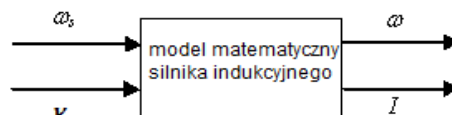
$$(3) \quad Q = \frac{k}{N} \sum_{i=1}^N (I(i) - \hat{I}(i))^2 + \frac{1}{N} \sum_{i=1}^N (\omega(i) - \hat{\omega}(i))^2$$

przy czym: N oznacza liczbę pomiarów, „ $\hat{}$ ” – rozwiązanie modelu matematycznego silnika indukcyjnego, natomiast k – współczynnik wagowy wyznaczany w pracy [20] eksperymentalnie, tak żeby zachować kompromis pomiędzy wartością sumy kwadratów błęd prądu stojana I oraz błęd prędkości kątownej ω .

Rysunek 1 przedstawia model matematyczny silnika indukcyjnego z uwzględnieniem sygnałów wejściowych i wyjściowych.

W układzie współrzędnych d - q (1)-(2) sygnałami wejściowymi silnika są pulsacja synchroniczna ω_s oraz amplituda wektora napięcia stojana v , a sygnałami wyjściowymi – prędkość kątowna ω i amplituda I wektora prądu stojana, określona jako

$$(4) \quad I = \sqrt{I_d^2 + I_q^2}$$



Rys.1. Model matematyczny obiektu identyfikacji z określeniem sygnałów wejściowych i wyjściowych [20]

Wybór kryterium stopu algorytmu genetycznego

Sprecyzowanie odpowiedniego kryterium stopu algorytmu genetycznego, zapewniającego otrzymanie oczekiwanego rozwiązania, przy możliwie najmniejszym nakładzie obliczeń, w wielu przypadkach jest zadaniem bardzo trudnym. W dużej mierze zależy od konkretnego, rozwiązywanego problemu. Autor pracy [1] posłużył się nawet stwierdzeniem, że dobór optymalnego kryterium stopu (biorąc pod uwagę czas obliczeń i wyniki badań) jest niemożliwy, ponieważ zbieżność AG ma charakter asymptotyczny, więc gdy rośnie liczba iteracji, wtedy wzrasta prawdopodobieństwo zlokalizowania ekstremum globalnego (minimum/maksimum odpowiednio do rozwiązywanego problemu) [1]. Niezwykle trudno jest przeprowadzić analizę zdolności eksploracyjnych algorytmu polegających na opuszczaniu obszarów występowania ekstremów lokalnych, czyli tzw. pułapek. Jeżeli znane są wartości, stanowiące rozwiązanie zadania, np. wartości funkcji celu, to można w oparciu o ich znajomość przyjąć jedno z najprostszych kryteriów stopu.

Ogólnie kryteria zatrzymania AG można podzielić na dwie grupy. Pierwsza grupa obejmuje warunki monitorujące wartości funkcji przystosowania/celu osobników, natomiast druga grupa – koncentruje się na określeniu zdolności algorytmu genetycznego do eksploracji przestrzeni genotypów, co warunkuje odporność na ekstrema lokalne i jest przede wszystkim wynikiem różnorodności populacji bazowej [1]. Poniżej omówiono wybrane sposoby zatrzymania procesu genetycznego, cieszące się największym zainteresowaniem, ze względu na ogromne możliwości ich adaptacji do różnych zastosowań.

Jednym z najprostszych, a zarazem najczęściej stosowanym kryteriów stopu jest ustalenie tzw. zadanej liczby iteracji AG, co polega na zatrzymaniu algorytmu, gdy liczba iteracji osiągnie założoną przez użytkownika programu wartość. Metoda ta, w literaturze była z powodzeniem wykorzystana w optymalizacji funkcji, czy zagadnieniach z obszaru badań operacyjnych. Ustalenie odpowiedniej liczby iteracji wymaga przeprowadzenia wielu obliczeń i znajomości problemu, ponieważ tak należy ustalić liczbę iteracji, aby algorytm niepotrzebnie nie wydłużał czasu procesu. Bez przeprowadzenia badań nie można podać, jaka liczba iteracji będzie satysfakcjonująca. W zależności od problemu może być duży rozrzut przyjętej liczby iteracji, ponieważ w jednym zadaniu może wystarczyć przykładowo 100 iteracji, natomiast w innym aż 10000.

Pewną modyfikację omówionego wyżej kryterium stanowi zadany czas procesu. W zastosowaniach praktycznych warunk ten jest jednak zdecydowanie rzadziej stosowany, niż przyjęta liczba iteracji.

Kolejnym z kryteriów zatrzymania algorytmu jest liczba wywołań funkcji celu/przystosowania, dotyczy to np. algorytmów genetycznych/ewolucyjnych, w których następuje częściowa wymiana osobników populacji. Takie podejście polega ogólnie na tym, że część populacji przechodzi do następnej iteracji bez żadnych zmian. Zastosowanie tego warunku stopu zakłada, że programista posiada wiedzę o cechach analizowanej funkcji [1, 5, 20].

W większości problemów praktycznych trudno jest niestety przewidzieć, jaka powinna być założona liczba iteracji, czas lub liczba wywołań funkcji. Jeśli ww. zadana liczba będzie za duża, wtedy czas obliczeń będzie proporcjonalnie dłuższy, natomiast gdy będzie za mała, to wynik będzie odbiegał od wartości oczekiwanej. Z uwagi na powyższe, jeden z najczęściej używanych sposobów zatrzymania algorytmu bazuje na połączeniu powyższych warunków. Z reguły zakłada się z góry przyjętą maksymalną liczbę iteracji, ale dodatkowe kryterium stopu (najczęściej uwzględniające wiedzę o problemie) pozwala na wcześniejsze zakończenie przebiegu algorytmu. Dodatkowy warunek zatrzymania może na przykład opierać się na określeniu szansy uzyskania poprawy wyników. Można zatem wyróżnić dwa podstawowe rodzaje kryteriów stopu. Pierwszy z nich polega na zatrzymaniu przebiegu genetycznego, gdy po ustalonej liczbie pokoleń dalsze działanie AG nie poprawia uzyskanych wyników procesu. Natomiast drugi - analizuje genotyp, co w praktyce sprowadza się do sprawdzania liczby ustalonych alleli (w tym przypadku konieczne jest podanie procentowej liczby ustalonych alleli w populacji). Warunek ten jest dość rzadko stosowany, ponieważ wpływa w sposób istotny na czas obliczeń [1, 5, 20].

Następny znany z literatury sposób zatrzymania AG (określany za pomocą odchyłeń standardowych), oceniający jego zdolność do przeszukiwania przestrzeni, bierze pod uwagę różnorodność populacji. Różnorodność populacji świadczy o odporności AG na lokalizowanie ekstremów lokalnych zamiast globalnego. Algorytm, gdzie populacje wykazują znaczną różnorodność szybko tworzy nowe, potencjalne rozwiązania, a zanik różnorodności powoduje przeszukiwanie wąskich przestrzeni, co w konsekwencji może doprowadzić do przedwczesnej zbieżności algorytmu. Odchylenie standardowe stanowi uproszczoną miarę różnorodności populacji i dlatego w niektórych przypadkach w wyborze tego kryterium stopu należy zachować pewną ostrożność [1]. W przypadku nagłego zaniku różnorodności populacji, np. w konsekwencji selekcji metodą ruletki, należy zakończyć działanie AG i zastosować metodę dostrajania lokalnego [1].

Powyżej przedstawiono najczęściej stosowane kryteria zatrzymania algorytmów genetycznych, które zdaniem autora zasługują na szczególną uwagę. Na podstawie zaprezentowanych informacji można wyciągnąć wniosek, że wybór możliwie najlepszemu warunkowi stopu jest problemem trudnym i nie istnieją gotowe wskazówki dotyczące takiego wyboru. Ogólna metodyka takiego postępowania polega na wnikliwej analizie problemu, z uwzględnieniem wiedzy o przyjętej strukturze algorytmu genetycznego (struktura AG również wpływa na przebieg procesu genetycznego) i doborze takiego kryterium stopu, które zapewni otrzymanie jak najlepszych wyników, w możliwie najkrótszym czasie.

Wyniki badań

Identyfikację modelu matematycznego silnika przeprowadzono na podstawie pomiarów stanu nieustalonego odpowiedzi czasowej prędkości kątowej ω i prądu stojana I , na skokową zmianę wartości napięcia stojana $v = 311 \cdot 1(t)$ V i pulsacji synchronicznej $\omega_s = 314 \cdot 1(t)$ rad/s. Identyfikowane parametry modelu matematycznego silnika indukcyjnego wyznaczono w oparciu o minimalizację błędu średniokwadratowego amplitudy prądu stojana I oraz prędkości kątowej ω silnika i jego modelu (3) przy użyciu algorytmu genetycznego. W symulacji komputerowej procesu identyfikacji przyjęto

następujące wartości parametrów modelu matematycznego silnika, takie jak: $a_1=521,4$, $a_2=280,1$, $a_3=54,2$, $J=0,04$ kgm² i $R_s=2,95$ Ω . Wartości parametrów modelu silnika zaczerpnięto z pracy [24].

Analizowano wpływ zastosowanego kryterium zatrzymania algorytmu genetycznego na wyniki procesu identyfikacji eksperymentalnej z uwzględnieniem wymaganej liczby iteracji AG oraz czasu obliczeń numerycznych. Za pomocą współczynników korelacji wielowymiarowej R_{ω} , R_I oceniono zgodność przebiegów czasowych prędkości kątowej silnika i prądu silnika oraz jego modelu matematycznego.

Opublikowane doświadczenia przeprowadzone przez autora wykazały, że algorytmy genetyczne zapewniają znaczne szanse zlokalizowania minimum globalnego wskaźnika jakości identyfikacji, co jest rezultatem specyficznego charakteru działania tych algorytmów. Uwzględniając stochastyczne elementy losowości AG każde pojedyncze uruchomienie procedury identyfikacji może dać trochę inny wynik, dlatego w zamieszczonych wynikach badań eksperymentalnych został podany wynik średni z 10-ciu doświadczeń.

Badania koncentrowały się na analizie wpływu zastosowanego kryterium zatrzymania AG na wyniki identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego, takie jak: zidentyfikowane wartości parametrów, liczba iteracji i czas procesu. W tym celu rozważono cztery, najczęściej stosowane warunki stopu, tj.:

- zadaną liczbę iteracji,
- odchylenie standardowe wartości wskaźnika jakości identyfikacji Q populacji,
- wartość funkcji przystosowania najlepszego osobnika populacji równa wartości funkcji przystosowania osobnika najgorszego,
- zadana z góry liczba iteracji, przy czym dodatkowe kryterium stopu ogólnie określone brakiem poprawy wskaźnika jakości Q w kolejnych pokoleniach.

W tabeli 1 przedstawiono wyniki identyfikacji eksperymentalnej modelu matematycznego silnika indukcyjnego z zastosowaniem algorytmu genetycznego. Przyjęto następujące oznaczenia kryteriów stopu, a mianowicie: A - zadana liczba iteracji AG, B - odchylenie standardowe wartości wskaźnika Q populacji, C - wartość funkcji przystosowania osobnika najlepszego i najgorszego oraz D - dodatkowe kryterium stopu pozwalające na zakończenie procesu, gdy w kolejnych n - pokoleniach nie następuje poprawa wartości wskaźnika jakości Q .

Tabela 1. Wyniki identyfikacji eksperymentalnej z zastosowaniem algorytmu genetycznego


Kryterium stopu	Wyniki średnie									
	a_1	a_2	a_3	J	R_s	Q	Liczba iteracji	Czas [s]	R_{ω}	R_I
A	533,073	290,876	56,871	0,039	3,075	42,481	300	720	0,999	0,991
B	528,012	289,435	56,022	0,039	2,998	42,453	280	660	0,999	0,991
C	540,326	291,532	57,865	0,039	3,247	42,506	278	600	0,999	0,991
D	523,315	286,023	54,567	0,040	2,954	41,800	210	475	1,000	0,992

Wyniki badań eksperymentalnych wskazują, że warunek zatrzymania algorytmu genetycznego ma wpływ przede wszystkim na czas analizowanego procesu identyfikacji


parametrycznej, natomiast na zbieżność zdecydowanie mniejszy (w przypadku A - pod warunkiem odpowiednio dobranej liczby iteracji do wymiaru problemu). Zastosowanie w kolejnych badaniach kryteriów A, B, potem C, a następnie D potwierdza słuszność wprowadzanych w algorytmie zmian. Oceniając czas obliczeń, najlepsze wyniki uzyskano dla warunku stopu D, najgorsze dla A. Zastosowanie kryteriów B i C dało pod względem porównywalne wyniki. Z uwagi na wartości identyfikowanych parametrów warunek D pozwolił na otrzymanie najlepszego rozwiązania.

Rysunki 2-9 przedstawiają w sposób graficzny wpływ zastosowanego warunku zatrzymania algorytmu genetycznego w problemie identyfikacji.

Na rysunku 2 pokazano przykładowy wykres zbieżności procesu identyfikacji eksperymentalnej przy użyciu kryterium zatrzymania określonego zadaną z góry przez użytkownika programu liczbą iteracji.




Rys.2. Wykres najlepszego osobnika z populacji reprezentowany przez wartość wskaźnika jakości Q w procesie identyfikacji eksperymentalnej (kryterium stopu AG określone zadaną liczbą iteracji)




Rys.3. Wykres różnorodności populacji wynikowej (kryterium stopu AG określone zadaną liczbą iteracji)

Zadana liczba iteracji jako kryterium stopu została ustalona na właściwym poziomie, ponieważ wykres różnorodności populacji wynikowej (rysunek 3) wskazuje na stagnację algorytmu genetycznego. Zwiększenie liczby iteracji AG nie przyniosłoby istotnej poprawy wyniku.

Analizując wykres najlepszego osobnika w poszczególnych iteracjach AG (rysunek 4) można zauważyć, że zastosowanie warunku stopu określonego wartością odchylenia standardowego umożliwiło nieznaczne skrócenie czasu identyfikacji. Natomiast wykres populacji końcowej (rysunek 5) oznacza całkowity zanik różnorodności tej populacji. Otrzymano niewiele lepsze rozwiązanie, niż w pierwszym rozważanym przypadku (rysunek 3), ale mniejszym kosztem obliczeń (co jest istotne przy stosowaniu algorytmów genetycznych).




Rys.4. Wykres najlepszego osobnika z populacji reprezentowany przez wartość wskaźnika jakości Q (kryterium stopu AG określone wartością odchylenia standardowego populacji)




Rys.5. Wykres różnorodności populacji wynikowej (kryterium stopu AG określone wartością odchylenia standardowego populacji)

Wykresy przedstawione na rysunkach 6 i 7 zostały sporządzone dla zilustrowania procesu identyfikacji parametrycznej z wykorzystaniem w algorytmie genetycznym warunku stopu określonego wartością funkcji przystosowania najlepszego i najgorszego osobnika. Rysunek 6 wskazuje, że w efekcie zastosowania ww. warunku zatrzymania otrzymano wyniki porównywalne (z uwagi na wymaganą liczbę iteracji AG oraz otrzymane rozwiązanie), do uzyskanych przy użyciu kryterium stopu określonego wartością odchylenia standardowego populacji. Wartości wskaźnika jakości identyfikacji Q w ostatnim pokoleniu świadczą o stagnacji algorytmu genetycznego, a więc o całkowitym zaniku różnorodności danej populacji (rysunek 7).




Rys.6. Wpływ warunku zatrzymania określonego wartością funkcji przystosowania na zbieżność procesu identyfikacji eksperymentalnej

Uwzględnienie warunku zatrzymania, w którym algorytm genetyczny kończy działanie, gdy w kolejnych n - pokoleniach nie następuje poprawa wartości wskaźnika Q najlepszego osobnika danej populacji umożliwiło uzyskanie lepszego rozwiązania (w porównaniu do wcześniej omówionych kryteriów stopu) znacznie mniejszym nakładem obliczeń numerycznych, co w konsekwencji spowodowało skrócenie czasu rozpatrywanego procesu (rysunek 8).




Rys.7. Wykres różnorodności populacji wynikowej AG, przy uwzględnieniu kryterium stopu określonego wartością funkcji przystosowania




Rys.8. Wykres zbieżności procesu identyfikacji eksperymentalnej dla warunku stopu w postaci poprawy wartości wskaźnika jakości Q

Populacja wynikowa przedstawiona na rysunku 9 nie straciła zupełnie różnorodności, ale z uwagi na bardzo znikome różnice w wartościach wskaźnika jakości Q poszczególnych osobników populacji wynikowej, w następnym kroku działania AG nie należy oczekiwać znacznej poprawy wyników.



Rys.9. Wykres różnorodności populacji wynikowej AG, przy uwzględnieniu kryterium stopu określonego poprawą wartości wskaźnika jakości Q



Rys.10. Porównanie przebiegów czasowych silnika (linia ciągła) i modelu matematycznego (linia przerywana)

Na rysunku 10 przedstawiono porównanie odpowiedzi czasowych prędkości kątowej ω i prądu stojana I silnika oraz wyznaczone w procesie identyfikacji parametrycznej. Uzyskano dobrą zbieżność ww. przebiegów czasowych, co potwierdza wartości współczynników wielowymiarowych (tabela 1).

Wnioski

W pracy analizowano wpływ zastosowanego kryterium zatrzymania algorytmu genetycznego na przykładzie identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego. Badania eksperymentalne zrealizowano przy wykorzystaniu czterech warunków stopu AG, uwzględniających zadaną liczbę iteracji, wartość odchylenia standardowego populacji, wartość funkcji przystosowania osobników oraz dodatkowe kryterium oceniające ogólnie poprawę wskaźnika jakości Q w kolejnych populacjach. Przeprowadzona analiza wpływu warunku zatrzymania algorytmu genetycznego pozwoliła na wybranie takiego kryterium stopu, które spośród rozważanych zapewniło otrzymanie dobrej zbieżności i dokładności procesu, przy jak najmniejszym nakładzie obliczeniowym.

Wykazano, że efektywność AG zależy w dużej mierze od właściwego doboru kryterium stopu, natomiast zdecydowanie mniejszy wpływ ma na zbieżność procesu (zakładając odpowiednio zaprojektowany AG i prawidłowo dobrane parametry kontrolne dla danego problemu). Pierwszy z rozważanych warunków stopu wymaga największej wiedzy o problemie, ponieważ tak należy wybrać zadaną liczbę iteracji, aby algorytm osiągnął minimum globalne wskaźnika jakości identyfikacji w możliwie krótkim czasie. W celu właściwego określenia odpowiedniej liczby iteracji należy przeprowadzić szereg wstępnych badań, na podstawie których można zaobserwować, jaka liczba iteracji statystycznie prowadzi do stagnacji algorytmu genetycznego. Kolejne dwa z rozpatrywanych kryteriów zapewniły uzyskanie porównywalnych wyników identyfikacji, biorąc pod uwagę zbieżność procesu oraz wymagany nakład obliczeń numerycznych. Ze statystycznego punktu widzenia najmniej czasochłonnym warunkiem zatrzymania przebiegu AG jest przyjęcie liczby pokoleń, w których wartość wskaźnika jakości najlepszego osobnika w populacji nie ulega poprawie (przy ewentualnym założeniu innych pomocniczych warunków narzuconych na program optymalizujący).

Autorzy: dr inż. Katarzyna Rutczyńska-Wdowiak, Politechnika Świętokrzyska, Katedra Systemów Informatycznych, ul. Tysiąclecia Państwa Polskiego 7, 25-314 Kielce, E-mail: K.Rutczynska@tu.kielce.pl

LITERATURA

- [1] Arabas J., Wykłady z algorytmów ewolucyjnych, *Wydawnictwa Naukowo-Techniczne* (2004)
- [2] Dybkowski M., Orłowska-Kowalska T., Estymacja prędkości i wybranych parametrów schematu zastępczego silnika indukcyjnego w beczujnikowym układzie napędowym, *Przegląd Elektrotechniczny*, 88 (2012), 4b, 64-69
- [3] El-Mihoub Tarek A., Hoppgood A., Nolle L., Battersby A., Hybrid Genetic Algorithms: A Review. *Engineering Letters, EL_13_2_11 Advance online publication: 4 August* (2006)
- [4] Ghandar, A., Michalewicz, Z., Schmidt, M., To, T.-D., Zurbrugg, R., Computational Intelligence for Evolving Trading Rules, *IEEE Transactions on Evolutionary Computation*, 13 (2009), No. 1, 71- 86
- [5] Goldberg D. E., Algorytmy genetyczne i ich zastosowania, *Wydawnictwa Naukowo-Techniczne* (2003)

- [6] Gorzalczany M. B., Rudzinski F., Accuracy vs. Interpretability of Fuzzy Rule-Based Classifiers: An Evolutionary Approach, *Lecture Notes in Computer Science*, 7269 (2012), 222-230
- [7] Gorzalczany M. B., Rudzinski F., Genetic Fuzzy Rule-Based Modeling of Dynamic Systems Using Time Series, *Lecture Notes in Computer Science*, 7269 (2012), 231-238
- [8] Gorzalczany M. B., Rudzinski F., A Modified Pittsburg Approach to Design a Genetic Fuzzy Rule-Based Classifier from Data, *Lecture Notes in Computer Science*, 6113 (2010), 88-96
- [9] Grzyb A., Algorytmy ewolucyjne, *Optymalizacja i polioptymalizacja w technice*, Wyd. Politechniki Koszalińskiej, (2011), 263-281
- [10] Hingston P. F., Barone L. C., Michalewicz Zb., Design by Evolution, *Advances in Evolutionary Design*, Springer-Verlag (2008)
- [11] Kisielewski P., Grzyb A., Algorytmy ewolucyjne w optymalizacji z dwuwartościowymi zmiennymi decyzyjnymi, *Mat. XXVIII Konferencji Naukowej Polioptymalizacja i CAD*, Wyd. Politechniki Koszalińskiej, (2009)
- [12] Lubo F. G., Lima C. F., Michalewicz Zb., Parameter Setting in Evolutionary Algorithms, *Springer-Verlag* (2010)
- [13] Michalewicz Zb., The Emperor is Naked: Evolutionary Algorithms for Real-World Applications, *ACM Ubiquity* (2012), 1 - 13
- [14] Michalewicz Zb., Fogel D. B., Jak to rozwiązać, czyli nowoczesna heurystyka, *Wydawnictwa Naukowo-Techniczne* (2006)
- [15] Orłowska-Kowalska T., Szabat K., Ritter W., Identyfikacja parametrów silnika indukcyjnego za pomocą algorytmów genetycznych, *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów elektrycznych Politechniki Wrocławskiej* Nr 54, Studia i Materiały Nr 23 (2013)
- [16] Pełczewski Wł., Krynke M., Metoda zmiennych stanu w analizie dynamiki układów napędowych, *WNT* (1984)
- [17] Rutczyńska-Wdowiak K., Analiza wpływu wskaźnika jakości na wyniki identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego z zastosowaniem algorytmu genetycznego, *Przegląd Elektrotechniczny*, w druku (2016)
- [18] Rutczyńska-Wdowiak K., Grzesikiewicz W., Identyfikacja modelu matematycznego silnika PMSM z zastosowaniem algorytmu hybrydowego, *Logistyka* (2015), nr 3, 4188-4194
- [19] Rutczyńska-Wdowiak K., Algorytmy genetyczne w problemach optymalizacji, *Technika Transportu Szynowego* (2015), 12/2015
- [20] Rutczyńska-Wdowiak K., Analiza wpływu wartości współczynnika wagowego wskaźnika jakości w problemie identyfikacji modelu matematycznego silnika indukcyjnego z zastosowaniem algorytmu genetycznego, *Logistyka* (2014), nr 6
- [21] Rutczyńska-Wdowiak K., Analiza wpływu przestrzeni poszukiwań algorytmu genetycznego w problemie projektowania filtrów, *Przegląd Elektrotechniczny*, nr 89 (2013), 11, 256-259
- [22] Rutkowski L., Metody i techniki sztucznej inteligencji, *PWN* (2005)
- [23] Simon D., Evolutionary Optimization Algorithms, *Wiley & Sons* (2013)
- [24] Stefański T., Synteza adaptacyjnych algorytmów sterowania momentem falownikowego napędu samochodu elektrycznego z silnikiem indukcyjnym, *Z. N. Politechniki Świętokrzyskiej, seria Monografie, studia, rozprawy* (1995), nr 4
- [25] Utrata G., Rolek J., Kapłon A., Eksperymentalna identyfikacja parametrów wieloobwodowego po stronie wtórnej schematu zastępczego silnika indukcyjnego, *Zeszyty Problemowe-Maszyny Elektryczne* (2014) Nr 4/2014 (104), Katowice, 155-159