

doi:10.15199/48.2017.10.35

Skalowanie funkcji przystosowania w problemie identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego

Streszczenie. W pracy koncentrowano się na poprawie zbieżności i dokładności algorytmu genetycznego (AG) wykorzystanego w identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego. W tym celu dokonano modyfikacji funkcji przystosowania poprzez jej przeskalowanie. Próbowano określić, czy wprowadzona w AG modyfikacja wpłynie również na skrócenie czasu analizowanego procesu. Zasadność podjęcia tej tematyki wynika z faktu, że rozważany problem jest w literaturze zaliczany do trudnych i czasochłonnych, a więc należy poszukać sposobów, które zapewnią poprawę wyników identyfikacji.

Abstract. The work focused on improving the convergence and accuracy of genetic algorithm (GA) used in the parametric identification of induction motor mathematical model. For this purpose, modifications fitness function by the rescaling were made. They attempted to determine whether the modification introduced in the GA will also shorten the time analyzed process. Whether any of this subject stems from the fact, that the problem is considered in the literature classified as difficult and time-consuming, and therefore look for ways to provide improvement of identification. (The scaling of fitness function in problem of parametric identification of induction motor mathematical model).

Słowa kluczowe: algorytm genetyczny (AG), skalowanie funkcji przystosowania, identyfikacja parametryczna, silnik indukcyjny, model matematyczny.

Keywords: genetic algorithm (GA), scaling of fitness function, parametric identification, induction motor, mathematical model.

WstępProblem identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego z zastosowaniem algorytmów genetycznych i ewolucyjnych był analizowany przez autora w pracach [19, 20, 21, 22]. Rozważano wpływ wykorzystanej metody optymalizacji, przyjętej struktury algorytmu genetycznego (AG) oraz wybranych jego parametrów na wyniki identyfikacji. Wykazano, że zarówno dobór poszczególnych elementów algorytmu genetycznego, jak również kryterium zatrzymania algorytmu, czy też postać wskaźnika jakości ma znaczący wpływ na wyniki identyfikacji. Przedstawione w pracach badania pokazały, że identyfikacja parametryczna modelu matematycznego silnika indukcyjnego z zastosowaniem ww. metody jest zadaniem wymagającym znacznego nakładu obliczeń, co znacznie wydłuża czas procesu. Z drugiej jednak strony algorytmy genetyczne, zaliczane do obecnie szeroko stosowanej sztucznej inteligencji [1, 2, 3, 5, 8, 9, 10, 11, 12, 13, 14, 24], zapewniają większe prawdopodobieństwo wyznaczenia minimum globalnego wskaźnika jakości w porównaniu do metod klasycznych, ponieważ przeszukując przestrzeń poszukiwań rozwiązania nie utykają na minimach lokalnych.

Z uwagi na powyższe zasadne jest poszukiwanie mechanizmów, które wpłyną na poprawę skuteczności i efektywności algorytmu genetycznego. W niniejszej pracy skupiono się na określeniu znaczenia skalowania funkcji przystosowania na przebieg procesu genetycznego.

Skalowanie funkcji przystosowania jest jednym ze sposobów poprawy działania algorytmów genetycznych i ogólnie ma na celu zapewnienie odpowiedniego poziomu konkurencji między osobnikami danej populacji [6, 7].

Przy braku skalowania często występuje zjawisko dominowania pewnej liczby wybijających się osobników, co może spowodować w późniejszej fazie przedwczesną zbieżność algorytmu, a więc uzyskanie wyniku, który znacznie odbiega od oczekiwanego rozwiązania. Drugim powodem stosowania skalowania jest zapobieganie sytuacji, w której osobniki najlepsze i przeciętne otrzymują prawie identyczną liczbę potomków w kolejnych iteracjach AG [15, 16, 23].

Mechanizmy skalowania funkcji przystosowania były z powodzeniem stosowane już przez Bagleya i Rosenberga [6, 15]. W późniejszych latach badania nad skalowaniem doprowadziły do opracowania obecnie stosowanych typów

skalowania, do których można zaliczyć skalowanie liniowe, skalowanie σ -obcinające oraz skalowanie potęgowe [6, 15, 19, 23].

Według cytowanej literatury [4, 17, 18, 21, 25] problematyka modelowania matematycznego silników indukcyjnych ze względu na złożoność modelu jest zadaniem trudnym, a więc stanowi doskonały przykład dla zbadania, czy warto stosować skalowanie funkcji przystosowania w celu poprawienia zbieżności i dokładności oraz skrócenia czasu analizowanego procesu.

W dostępnej literaturze są powszechnie stosowane dwa modele matematyczne ww. silnika, tj. model sformułowany w wirującym zgodnie z wektorem napięcia stojana oraz w stacjonarnym układzie współrzędnych [18]. Ze względu na techniczne możliwości wykonania pomiarów, w badaniach wykorzystano model matematyczny silnika indukcyjnego w układzie współrzędnych $d-q$ wirującym zgodnie z wektorem napięcia stojana. Identyfikowane parametry modelu matematycznego silnika wyznaczono na podstawie minimalizacji wskaźnika jakości w postaci błędu średniokwadratowego amplitudy prądu stojana oraz prędkości kątowej silnika i jego modelu.

W badaniach eksperymentalnych wykorzystano silnik indukcyjny małej mocy. Analizowano wpływ zastosowanego skalowania na zbieżność, dokładność i czas procesu identyfikacji parametrycznej.

Skalowanie funkcji przystosowania

W klasycznym algorytmie genetycznym, skalowanie funkcji przystosowania jest stosowane dla zachowania kontroli nad liczbą kopii osobników, które przechodzą do kolejnej iteracji AG. Jest to bardzo istotne szczególnie dla algorytmów, które działają na małych populacjach osobników. Regulacja liczby kopii osobników ma znaczenie zarówno w początkowej, jak i w końcowej fazie algorytmu genetycznego. W pierwszych iteracjach AG wygenerowanie kilku osobników o wartości funkcji przystosowania znacznie większej od przystosowania pozostałych może doprowadzić do zdominowania przez nich kolejnych populacji, co w konsekwencji prowadzi do przedwczesnej zbieżności AG. Zbliżona sytuacja może mieć miejsce w końcowej fazie algorytmu, gdy populację cechuje mała różnorodność [6].

W ostatnim etapie można się jeszcze spotkać z innym zjawiskiem, a mianowicie populacja wykazuje wprawdzie znaczną różnorodność, ale średnia wartość funkcji przystosowania niewiele odbiega od maksymalnej wartości. W takim przypadku osobniki przeciętne i najlepsze mogą otrzymać prawie taką samą liczbę potomków w następnych iteracjach. Zasada przetrwania najlepszych osobników, na której bazują omawiane algorytmy może sprowadzić się do błędzenia przypadkowego wśród osobników przeciętnych [6, 15].

Podstawowym zadaniem skalowania funkcji przystosowania jest zapobieganie przedwczesnej zbieżności algorytmu, rozumianej jako dominacja nieoptymalnych osobników [23].

Dla uniknięcia wyżej wymienionych problemów, które w niekorzystny sposób wpływają na przebieg tradycyjnego procesu genetycznego bazującego na selekcji metodą ruletki, jak również opóźnić zbieżność zmodyfikowanych algorytmów genetycznych, które uwzględniają inne metody selekcji i krzyżowania, stosuje się, takie mechanizmy jak [6, 15, 19, 21, 23]:

- skalowanie liniowe (ang. *linear scaling*),
- skalowanie σ -obcinające (ang. *sigma truncation scaling*),
- skalowanie zgodne z prawem potęgowym (ang. *power law scaling*).

Skalowanie jest realizowane poprzez odpowiednie przekształcenie funkcji przystosowania, które jest realizowane w inny sposób, zależnie od przyjętego rodzaju skalowania [23].

W skalowaniu liniowym [28, 56, 61, 92] rzeczywista funkcja przystosowania osobnika ulega przeskalowaniu, zgodnie z zależnością [6, 15]

$$(1) \quad F'_p = \beta_1 F_p + \beta_2$$

przy czym: F_p - funkcja przystosowania danego osobnika, F'_p - funkcja przystosowania po skalowaniu, natomiast współczynniki β_1 i β_2 należy dobrać według kryteriów, podanych przez Goldberga w pracy [6], zgodnie z którymi konieczne jest:

- zachowanie stałej wartości średniej funkcji przystosowania,
- ustalenie maksymalnej wartości wyskalowanej funkcji przystosowania na poziomie określonej krotności średniej funkcji przystosowania (najczęściej 2-krotnej).

Najczęściej wartości parametrów β_1 i β_2 nie są zależne od zadania, ale przyjmuje się, że są stałe w całym przebiegu algorytmu [15]. Spełnienie tych warunków gwarantuje, że osobnik najlepszy otrzyma tylu potomków, ile wynosi założona krotność, natomiast osobnik przeciętny tylko jednego potomka. Stosowanie ww. mechanizmu wymaga jednak zwrócenia uwagi na generowane wartości funkcji przystosowania [6, 15]. W przypadku ujemnych wartości funkcji przystosowania można posłużyć się skalowaniem σ -obcinającym, które zamienia wszystkie ujemne wartości tej funkcji na wartość zero [6].

Związek między funkcją przystosowania a odchyleniem standardowym populacji można określić za pomocą skalowania σ -obcinającego, nazywane też obcinaniem typu sigma, albo obcinaniem na poziomie odchylenia standardowego [6, 15]. Funkcję przystosowania po skalowaniu F'_p przedstawia następująca zależność

$$(2) \quad F'_p = F_p + (\bar{F}_p - b\sigma_{p(t)})$$

gdzie: \bar{F}_p - średnia wartość funkcji przystosowania w populacji, b - liczba naturalna wybierana doświadczalnie, $\sigma_{p(t)}$ - odchylenie standardowe populacji [6, 15].

Współcześnie najpopularniejszym i zarazem najczęściej stosowanym sposobem skalowania jest skalowanie zgodne z prawem potęgowym zaproponowane przez Gillies'a [6], określane również jako skalowanie potęgowe, czy też skalowanie potęgą [15]. Polega na podniesieniu pierwotnej funkcji przystosowania F_p do ustalonej potęgi k (bliskiej jedności)

$$(3) \quad F'_p = F_p^k$$

Model matematyczny silnika indukcyjnego

W niniejszej pracy wykorzystano znany z literatury [18] model matematyczny silnika indukcyjnego sformułowany w wirującym układzie współrzędnych d - q , zorientowany zgodnie z wektorem napięcia stojana o postaci [18, 19, 22, 25]:

$$(4) \quad \begin{aligned} \frac{d}{dt}\phi_d(t) &= \phi_q(t)\omega_s(t) - R_s I_d(t) + v(t) \\ \frac{d}{dt}\phi_q(t) &= -\phi_d(t)\omega_s(t) - R_s I_q(t) \\ \frac{d}{dt}I_d(t) &= a_1\phi_d(t) + a_3\phi_q(t)\omega_e(t) - a_2 I_d(t) + \\ &+ I_q(t)\omega_s(t) - I_q(t)\omega_e(t) + a_3 v(t) \\ \frac{d}{dt}I_q(t) &= -a_3\phi_d(t)\omega_e(t) + a_1\phi_q(t) - I_d(t)\omega_s(t) + \\ &+ I_d(t)\omega_e(t) - a_2 I_q(t) \\ \frac{d}{dt}\omega_e(t) &= \frac{3p^2}{2J}(\phi_d(t)I_q(t) - \phi_q(t)I_d(t)) - \frac{P}{J}M_o(t) \end{aligned}$$

gdzie:

$$(5) \quad \begin{aligned} a_1 &= \frac{R_r}{\sigma L_s L_r}, \quad a_2 = \frac{R_s}{\sigma L_s} + \frac{R_r}{\sigma L_r}, \quad a_3 = \frac{1}{\sigma L_s} \\ \sigma &= \frac{L_s L_r - L_m^2}{L_s L_r} \end{aligned}$$

przyjęto następujące oznaczenia: 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_m - indukcyjność główna; L_s, L_r indukcyjność odpowiednio stojana, wirnika; ω - mechaniczna prędkość kątowna, ω_e - elektryczna prędkość kątowna (przy czym: $\omega_e = p\omega$); 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 [18].

Parametry modelu matematycznego silnika indukcyjnego (4)-(5) wyznaczono w procesie identyfikacji off-line przyjmując wskaźnik jakości stanowiący błąd średniokwadratowy amplitudy prądu stojana oraz prędkości kątowej silnika i modelu [19, 25]

$$(6) \quad Q = \frac{1}{N} \left(\sum_{i=1}^N (\omega(i) - \hat{\omega}(i))^2 + w \sum_{i=1}^N (I(i) - \hat{I}(i))^2 \right)$$

gdzie: N - liczba pomiarów, „ \wedge ” – rozwiązanie modelu matematycznego silnika indukcyjnego, w – współczynnik wagowy wyznaczany eksperymentalnie w pracy [22].

Oceniając zbieżność i dokładność procesu identyfikacji przyjęty wskaźnik jakości (6) zapewnia uzyskanie najlepszych wyników, co wykazano w pracy [19].

Rysunek 1 przedstawia uproszczony schemat stanowiska laboratoryjnego.



Rys.1. Uproszczony schemat stanowiska laboratoryjnego

Wyniki identyfikacji parametrycznej

Omówione w pracy typy skalowania funkcji przystosowania zostały z powodzeniem zastosowane w algorytmach genetycznych wykorzystanych do rozwiązania wielu różnych problemów z zakresu optymalizacji oraz badań operacyjnych. Ze względu na to, że identyfikacja modelu matematycznego silnika indukcyjnego jest trudnym, złożonym i czasochłonnym procesem zalecane jest wprowadzenie mechanizmów, które mogłyby się przyczynić do poprawy skuteczności i efektywności zastosowanych algorytmów. Z uwagi na to autor zdecydował się na zbadanie przydatności skalowania funkcji przystosowania w algorytmie genetycznym użytym do identyfikacji ww. modelu matematycznego.

Według cytowanej literatury, wybór odpowiedniego skalowania funkcji przystosowania najlepiej realizować w sposób eksperymentalny, ponieważ zapewnia to dobranie takiego rodzaju skalowania, które przynosi dla danego problemu możliwie największe korzyści.

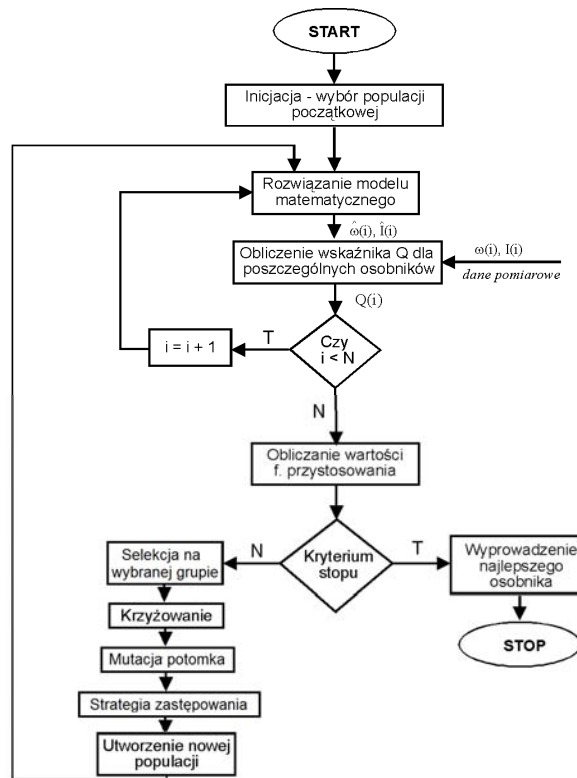
Prowadzone przez autora wstępne prace w zakresie zastosowań skalowania funkcji przystosowania wykazały, że najlepszą poprawę wyników przynosi stosowanie w problemie identyfikacji parametrycznej skalowania potęgowego. Jednak jego skuteczność zależy w dużej mierze od ustalenia odpowiedniej wartości potęgi k , która prowadzi do poprawy wyników identyfikacji.

W pracach [6, 15, 23] oraz literaturze w nich cytowanej uważa się, że dla uzyskania poprawy rezultatów, wartość potęgi k powinna zależeć od rozpatrywanego zagadnienia.

W niniejszej pracy badania dotyczyły określenia wpływu skalowania potęgowego funkcji przystosowania na wyniki identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego. W procesie identyfikacji przyjęto wskaźnik jakości określony zależnością (6). Identyfikowane parametry modelu silnika wyznaczono w procesie minimalizacji wskaźnika jakości z wykorzystaniem algorytmu genetycznego z częściową wymianą populacji, opartego między innymi na reprezentacji zmienno pozycyjnej, selekcji turniejowej z częściową wymianą i zastępowaniem osobników, operatorze krzyżowania oraz mutacji.

Rysunek 2 przedstawia w pewnym uproszczeniu schemat procesu identyfikacji parametrycznej modelu

matematycznego silnika indukcyjnego z zastosowaniem wybranego algorytmu genetycznego.



Rys.2. Schemat blokowy procesu identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego z zastosowaniem wybranego algorytmu genetycznego

W celu sprawdzenia poprawności działania zaimplementowanego przez autora algorytmu genetycznego wykonano symulację procesu identyfikacji modelu matematycznego silnika indukcyjnego. Oczekiwano uzyskanie wartości wskaźnika jakości bliskiej zero, dla zadanych parametrów modelu silnika, tj.: $L_m=0,222$ [H], $L_s=0,234$ [H], $L_r=0,251$ [H], $R_r=2,47$ [Ω], $R_s=2,95$ [Ω], $J=0,044$ [kgm^2][19]. Wyniki symulacji procesu identyfikacji pokazano w tabeli 1. Badania zrealizowano dla populacji 100 osobników przy zadanych znacznych przestrzeniach poszukiwań rozwiązania algorytmu genetycznego. Zgodność przebiegów czasowych prędkości kątowej silnika ω i prądu silnika I oraz jego modelu matematycznego oceniono za pomocą współczynników korelacji wielowymiarowej R_{ω} , R_I - odpowiednio dla przebiegów prędkości oraz prądu. Z uwagi na stochastyczne elementy algorytmu genetycznego, w zamieszczonych wynikach badań symulacyjnych podano wyniki najlepsze (oznaczone jako (1) w tabeli 1) oraz średnie z 10-ciu uruchomień procedury identyfikacji (oznaczone cyfrą - (2)). Wyniki najlepsze zostały określone najmniejszą uzyskaną wartością wskaźnika Q . Kryterium zatrzymania algorytmu genetycznego stanowi poprawa w określonej liczbie iteracji najlepszej wartości wskaźnika jakości identyfikacji, ponieważ w pracy [21] wykazano, że dla rozważanego problemu identyfikacji ten warunek stopu zapewnia krótszy czas procesu, nie pogarszając zbieżności.

Algorytm genetyczny zaimplementowany do rozwiązania zadania identyfikacji parametrycznej działa prawidłowo, ponieważ parametry modelu matematycznego silnika indukcyjnego zostały wyznaczone poprawnie, o czym świadczą wyniki symulacji komputerowej pokazane w tabeli 1.


Tabela 1. Wyniki symulacji procesu identyfikacji modelu matematycznego silnika indukcyjnego z zastosowaniem algorytmu genetycznego

Wyniki	L_m [H]	L_r [H]	L_s [H]	J [kgm ²]	R_s [Ω]	R_r [Ω]	Q	R_ω	R_I	Czas [s]
(1)	0,222	0,251	0,234	0,044	2,95	2,47	0,000	1,000	1,000	241
(2)	0,223	0,251	0,235	0,045	2,95	2,47	0,000	1,000	1,000	265

Zestawienie uzyskanych w procesie identyfikacji eksperymentalnej parametrów modelu matematycznego silnika, tj.: L_m , L_s , L_r , R_r , R_s oraz J przedstawiono w tabeli 2. Są to wyniki średnie z 10-ciu przebiegów algorytmu. Analizowano wpływ zastosowanego skalowania potęgowej funkcji przystosowania na wyniki identyfikacji eksperymentalnej, tj. na zbieżność, dokładność i czas procesu. Dla porównania przedstawiono wyniki identyfikacji eksperymentalnej bez skalowania funkcji przystosowania (w tabeli 2 oznaczono literą A) oraz ze skalowaniem potęgowym (litera B). W omawianej implementacji algorytmu genetycznego, wartość potęgi skalowania została ustalona doświadczalnie, tak aby uzyskać największą poprawę wyników identyfikacji.

Tabela 2. Analiza wpływu skalowania potęgowej funkcji przystosowania na wyniki identyfikacji eksperymentalnej modelu matematycznego silnika indukcyjnego z zastosowaniem algorytmu genetycznego

Wyniki średnie	L_m [H]	L_r [H]	L_s [H]	J [kgm ²]	R_s [Ω]	R_r [Ω]	Q	R_ω	R_I	Czas [s]
(A)	0,254	0,291	0,238	0,039	3,24	2,77	45,685	0,998	0,991	423
(B)	0,224	0,266	0,234	0,042	2,96	2,45	41,200	1,000	0,992	390



Rys.3. Przykładowe porównanie odpowiedzi czasowych silnika (linia ciągła) i modelu matematycznego (linia przerywana), dla wyznaczonych w procesie identyfikacji eksperymentalnej parametrów, tj. L_m , L_s , L_r , R_r , R_s , J

Zaprezentowane wyniki badań identyfikacji eksperymentalnej dowodzą, że zasadne okazało się wprowadzenie skalowania funkcji przystosowania, ponieważ otrzymano poprawę zbieżności, dokładności rozważanego procesu oraz skrócenie czasu, co w przypadku identyfikacji parametrycznej modelu silnika indukcyjnego ma znaczenie z uwagi na to, że jest to proces zaliczany do trudnych ze względu na złożoność obiektu oraz czasochłonny.

Na rysunku 3 porównano zarejestrowane przebiegi czasowe silnika z odpowiednimi przebiegami otrzymanymi

w procesie identyfikacji z rozwiązania modelu matematycznego silnika. Charakterystyki silnika wyznaczono dla skokowej zmiany napięcia stojana $v = 311 \cdot 1(t)$ V i pulsacji synchronicznej $\omega_s = 314 \cdot 1(t)$ rad/s. Można zauważyć, że otrzymano bardzo dobrą zgodność przebiegów czasowych silnika i jego modelu matematycznego.

Wnioski

Praca przedstawia analizę zastosowanego skalowania funkcji przystosowania w problemie identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego. Badania eksperymentalne wykonano dla silnika indukcyjnego małej mocy. Parametry modelu matematycznego silnika indukcyjnego identyfikowano na podstawie odpowiedzi czasowych prędkości kątowej i prądu stojana silnika oraz rozwiązania modelu, uzyskanego na podstawie minimalizacji przyjętego wskaźnika jakości z zastosowaniem algorytmu genetycznego z częściową wymianą populacji i zastępowaniem osobników populacji.

Wykazano, że ze względu na złożoność rozważanego problemu zasadne jest poszukiwanie mechanizmów, które przyczynią się do poprawienia wyników identyfikacji parametrycznej i zmniejszą nakład obliczeń numerycznych. Wprowadzenie skalowania potęgowej funkcji przystosowania, dla ustalonej eksperymentalnie wartości potęgi spełniło postawione w pracy założenia, czyli poprawę zbieżności i dokładności, a także skrócenie czasu identyfikacji, co w przypadku procesów czasochłonnych ma istotne znaczenie.

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] Bonyadi M. R., Michalewicz Zb., Analysis of stability, local convergence and transformation sensitivity of a variant of particle swarm optimization algorithm, *IEEE Transactions on Evolutionary Computation*, Vol. 20, (2016), No. 3, pp. 370 - 385
- [2] Bonyadi M. R., Michalewicz Zb., Stability analysis of the particle swarm optimization without stagnation, *IEEE Transactions on Evolutionary Computation*, Vol. 20, (2016), No. 5, pp. 814 - 819
- [3] Derugo P., Szabat K., Adaptive neuro-fuzzy PID controller for nonlinear drive system, *COMPEL: The International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, Vol. 34 (2015), Iss. 3, pp. 792 - 807
- [4] Dybkowski M., Orłowska-Kowalska T., Estymacja prędkości i wybranych parametrów schematu zastępczego silnika indukcyjnego w beczujnikowym układzie napędowym, *Przeгляд Elektrotechniczny*, 88 (2012), 4b, 64-69
- [5] 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
- [6] Goldberg D. E., Algorytmy genetyczne i ich zastosowania, *Wydawnictwa Naukowo-Techniczne*, (2003)
- [7] Goldberg D. E., Genetic Algorithms in Search, Optimization and Machine Learning (2002)
- [8] 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
- [9] Gorzalczany M. B., Piekoszewski J., Rudzinski F., Microarray Leukemia gene data clustering by means of generalized self-organizing neural networks with evolving tree-like structures, *Lecture Notes in Computer Science*, 7269 (2015), 15-25
- [10] Gorzalczany M. B., Piekoszewski J., Rudzinski F., Generalized Tree-Like Self-Organizing Neural Networks with Dynamically Defined Neighborhood for Cluster Analysis, *Lecture Notes in Computer Science*, 8468 (2014), pp. 713-725

- [11] Grzyb A., Algorytmy ewolucyjne, *Optymalizacja i polioptymalizacja w technice*, Wyd. Politechniki Koszalińskiej, (2011), 263-281
- [12] Kisielewski P., Grzyb A., Algorytmy ewolucyjne w optymalizacji z dwuwartościowymi zmiennymi decyzyjnymi, *Mat. XXVIII Konferencji Naukowej Polioptymalizacja i CAD*, Wyd. Politechniki Koszalińskiej, (2009)
- [13] Kisielewski P., Zmodyfikowany algorytm węgierski optymalnego pokrycia zbiorów, *Mat. XXVIII Konferencji Naukowej Polioptymalizacja i CAD*, Wyd. Politechniki Koszalińskiej, (2009)
- [14] Lubo F. G., Lima C. F., Michalewicz Zb., Parameter Setting in Evolutionary Algorithms, *Springer-Verlag* (2010)
- [15] Michalewicz Zb., Genetic Algorithms + Data Structures = Evolution Programs, *Springer-Verlag Berlin Heidelberg GmbH* (2010)
- [16] Michalewicz Zb., Fogel D. B., How to Solve it: Modern Heuristics, *Springer* (2000)
- [17] 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* (2013), Nr 23
- [18] Pełczewski Wł., Krynke M., Metoda zmiennych stanu w analizie dynamiki układów napędowych, *WNT* (1984)
- [19] Rutczyńska-Wdowiak K., Analiza wpływu wskaźnika jakości na wyniki identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego z zastosowaniem algorytmu genetycznego, *Przegląd Elektrotechniczny*, R. 92 (2016), NR 4/2016, str. 202-204
- [20] Rutczyńska-Wdowiak K., Identyfikacja parametryczna modelu matematycznego silnika indukcyjnego z wykorzystaniem wybranego algorytmu ewolucyjnego, *Przegląd Elektrotechniczny*, R. 92 (2016), NR 7/2016, str. 170-173
- [21] Rutczyńska-Wdowiak K., Dobór kryterium zatrzymania algorytmu genetycznego na przykładzie identyfikacji parametrycznej modelu matematycznego silnika indukcyjnego, *Przegląd Elektrotechniczny*, R. 92 (2016), NR 12/2016, str. 283-288
- [22] 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
- [23] Rutkowski L., Metody i techniki sztucznej inteligencji, *PWN* (2005)
- [24] Simon D., Evolutionary Optimization Algorithms, *Wiley & Sons* (2013)
- [25] 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