

Roman MIKSIEWICZ

Katedra Maszyn i Urządzeń Elektrycznych
Politechniki Śląskiej

OPTIMALIZACJA SILNIKÓW 3-FAZOWYCH KLATKOWYCH PRZY ZASTOSOWANIU ALGORYTMU GENETYCZNEGO

Streszczenie. W artykule, na przykładzie 3-fazowego silnika klatkowego, przedstawiono możliwości zastosowania algorytmu genetycznego do optymalizacji jego obwodu elektromagnetycznego. Sformułowano zadanie optymalizacji z ograniczeniami, przyjmując zewnętrzną funkcję kary. Dla opracowanego programu komputerowego wykorzystującego AG istnieje możliwość wyboru 8 zmiennych decyzyjnych oraz ogólnej postaci funkcji celu. Dla analizowanego silnika pokazano zbiory rozwiązań dopuszczalnych (dla 2 zmiennych decyzyjnych) oraz wybrane wykresy funkcji celu. Zamieszczono wyniki obliczeń optymalizacyjnych dla różnych kryteriów jakości oraz przedstawiono przebiegi procesu optymalizacji w kolejnych generacjach. Istotny wpływ na przebieg obliczeń mają parametry algorytmu genetycznego. Na podstawie wyników wielu obliczeń przy tej samej funkcji celu stwierdzono zadowalającą z praktycznego punktu widzenia zbieżność algorytmu.


OPTIMIZATION OF 3-PHASE SQUIRREL-CAGE INDUCTION MOTORS USING GENETIC ALGORITHM

Summary. In the paper the possibilities of GA application to optimization of the electromagnetic circuit of a 3-phase induction motor are presented. The problem of optimization with constraints was formulated using the method of the external penalty function. For the developed computer program there is possibility of selection of 8 independent variables and the multiobjective function. For analyzed motor the feasible solution region (for two design variables) and the chosen diagrams of the objective functions were shown. The results of optimization calculations for different objective functions and the calculations process in the successive generations are presented. The genetic algorithm parameters influence essentially the calculation process. Basing on the results of many calculations for the same objective function it was stated that the algorithm convergence is satisfactory as far as practical applications are considered.

1. WSTĘP

Tradycyjnie, do optymalizacji w technice stosuje się metody deterministyczne. Jest to najczęściej zadanie programowania nieliniowego z ograniczeniami. W metodach deterministycznych efektywność algorytmu zależy od wielu czynników: określenia właściwego kierunku poszukiwań (zastosowania właściwej metody do danego zagadnienia), punktu startowego, kryterium zatrzymania. Przy zastosowaniu klasycznych algorytmów optymalizacyjnych, aby spełnić warunki jednoznacznego rozwiązania zadania optymalizacji i znaleźć ekstremum globalne, zbiór rozwiązań dopuszczalnych oraz funkcja celu muszą być wypukłe. Na podstawie wykonanych obliczeń można stwierdzić, że w przypadku optymalizacji obwodu elektromagnetycznego silnika indukcyjnego te warunki zwykle nie są spełnione. Przykładowo, na rys.1 przedstawiono wykresy warstwicowe dla funkcji celu $\eta_N \cos\varphi_N$ oraz kilku funkcji ograniczeń. Funkcje ograniczeń wyznaczają zbiór rozwiązań dopuszczalnych (obszar zakreskowany). Z rysunku tego wynika, że zbiór rozwiązań dopuszczalnych nie jest zbiorem wypukłym i w konsekwencji rozwiązanie może być niejednoznaczne.

W ostatnich latach nastąpił duży rozwój algorytmów niedeterministycznych - w tym algorytmów genetycznych (AG) i ewolucyjnych, symulowanego wyżarzania. Są one coraz częściej stosowane przy rozwiązywaniu wielu zagadnień technicznych. Dla różnego typu maszyn elektrycznych, zastosowania tych metod dotyczą, jak wynika z dotychczasowych



Rys.1. Wykresy warstwicy funkcji ograniczeń i funkcji celu ($\eta_N \cos\varphi_N$) dla zmiennych h_r i b_{dr}
 Fig.1. Contour plots of constraint functions and objective function ($\eta_N \cos\varphi_N$) for two design variables: h_r and b_{dr}

publikacji, optymalizacji przy projektowaniu i estymacji parametrów. Algorytmy genetyczne cechuje wysokie prawdopodobieństwo znalezienia optimum globalnego, są więc bardziej odpowiednie do zastosowania w optymalizacji. Algorytmy genetyczne korzystają z wielkości dyskretnej zmiennych decyzyjnych, co również jest ważną ich zaletą przy projektowaniu maszyn. Ze względu na konieczność wykonywania dużej liczby obliczeń funkcji celu, model obliczeniowy z użyciem AG musi być tak skonstruowany, aby połączyć odpowiednio czas obliczeń z gwarancją znalezienia optimum globalnego.

2. SFORMUŁOWANIE ZADANIA OPTYMALIZACJI

Aby sformułować zadanie optymalizacji, należy dokonać wyboru: zmiennych decyzyjnych, funkcji ograniczeń i funkcji celu (kryterium jakości). Ważnym zagadnieniem w projektowaniu maszyn elektrycznych jest fakt, że niektóre zmienne decyzyjne mają postać dyskretną (np. liczba zwojów, średnica przewodów). Stosując metody programowania nieliniowego zakłada się, że wszystkie zmienne przyjmują wartości ciągłe. Wobec tego po przeprowadzeniu optymalizacji należy dokonać zamiany niektórych wielkości ciągłych na wielkości dyskretnie i wykonać obliczenia dla tych zmiennych.

Dla opracowanego programu komputerowego istnieje możliwość wyboru następujących *zmiennych decyzyjnych*: średnica wewnętrzna stojana - d_s , długość pakietu stojana - l_s , liczba zwojów w zezwoju uzwojenia stojana - N_{cs} , średnica przewodu uzwojenia stojana - c_s , głębokość żłobka stojana - h_s , szerokość zęba stojana - b_{ds} , głębokość żłobka wirnika - h_r , szerokość zęba wirnika - b_{dr} .

Ograniczenia mogą dotyczyć: spełnienia określonych parametrów eksploatacyjnych, warunków technologicznych związanych z wykonaniem silnika oraz wymagań konstrukcyjnych. Przyjęto następujące *funkcje ograniczeń*: minimalny moment rozruchowy - m_{rmin} , maksymalny prąd rozruchowy - i_{rmax} , minimalny moment krytyczny - m_{krmin} , maksymalny współczynnik zapełnienia żłobka stojana - k_{qmax} , maksymalna gęstość prądu w uzwojeniu stojana - j_{smax} , maksymalna gęstość prądu w prętach uwojenia wirnika - j_{pmax} , minimalna szerokość żłobka wirnika w dolnej części - b_{r3min} , maksymalne indukcje w zębach stojana - B_{dsmax} i wirnika - B_{drmax} , maksymalne indukcje w jarzmach stojana i wirnika - B_{ysmax} , B_{yrmax} .

Zadanie optymalizacji polega na znalezieniu maksimum tej funkcji w zbiorze rozwiązań dopuszczalnych. W opracowanym programie wprowadzono uogólnioną *funkcję celu* (1), będącą sumą kryteriów częściowych. Przyjmując wartości zerowe współczynników wagowych, odpowiednio: w_{c1} , w_{c2} lub w_{c3} , można więc zadawać następujące kryteria częściowe: minimum masy uzwojenia i pakietu blach - m , maksymalny iloczyn współczynnika mocy i sprawności dla dowolnego obciążenia - $\eta \cos \varphi$, maksymalna dobroć rozruchu - $m_r / i_r * (\eta_n \cos \varphi_n)$.

$$F_c(x) = \frac{w_{c1}}{m_{Fe}(x) + m_u(x)} + w_{c2} \eta_n(x) \cos \varphi_n(x) + w_{c3} \frac{m_r}{i_r} \eta_n(x) \cos \varphi_n(x) \quad (1)$$

gdzie:

w_{ci} - współczynniki wagowe kryteriów częściowych.

W programie ograniczenia uwzględniono przyjmując metodę zewnętrznej funkcji kary. Funkcja przystosowania $F_p(x)$ (2) algorytmu genetycznego jest więc sumą funkcji celu $F_c(x)$ i zewnętrznej funkcji kary $P(x)$:

$$F_p(x) = F_c(x) + P(x) \quad (2)$$

gdzie:

$$P(x) = \sum_{i=1}^n w_i (p_i(x))^2, \quad (3)$$

$$p_i(x) = \begin{cases} 0 & \text{gdy } g_i(x) \leq 0 \\ \frac{g_{ic} - g_i(x)}{g_{ic}} & \text{gdy } g_i(x) > 0 \end{cases},$$

$p_i(x)$ - względna wartość i-tej funkcji ograniczeń, odniesiona do zadanej wartości ograniczenia g_{ic} ,

$g_i(x)$ - wartość i-tej funkcji ograniczeń dla współrzędnych x wektora zmiennych niezależnych,

g_{ic} - zadana wartość ograniczenia dla i-tej funkcji ograniczeń,


w_i - współczynnik wagowy i-tej funkcji ograniczeń,

x - wektor zmiennych decyzyjnych.

Odpowiednio dobrane współczynniki wagowe w_i zapewniają znalezienie rozwiązania w zbiorze rozwiązań dopuszczalnych.


Model maszyny powinien zagwarantować odpowiednią dokładność obliczeń. Zastosowany algorytm obliczeń elektromagnetycznych 3-fazowego silnika klatkowego bazuje na modelu obwodowym i uwzględnia nasycanie się obwodu od strumienia głównego i strumieni rozprożeń oraz wypieranie prądu w klatce wirnika. Parametry schematu zastępczego silnika nie są więc stałe. Obliczenia wielkości eksploatacyjnych silnika dla danego poślizgu są wykonywane iteracyjnie.

Obliczenia wykonano dla silnika 3-fazowego klatkowego o danych znamionowych: $P_n=3$ kW; $f_n=50$ Hz; $U_n=380$ V; $p=2$. Dla tego silnika wyznaczono dla dwóch par zmiennych decyzyjnych (N_{cs} , I_s) i (N_{cs} , c_s), przykładowe warstwiczne zbiory rozwiązań dopuszczalnych (rys.2 i 3), utworzone przez zadane funkcje ograniczające.





Rys.2. Zbiór rozwiązań dopuszczalnych oraz wykresy warstwiczne funkcji ograniczeń dla zmiennych decyzyjnych: (N_{cs} , l_s)

Fig.2. Feasible solution space and contour plots of constraint functions for design parameters: (N_{cs} , l_s)



Rys.3. Zbiór rozwiązań dopuszczalnych i wykresy warstwiczne funkcji celu ($\eta_n \cos \phi_n$) dla zmiennych decyzyjnych: (N_{cs} , c_s)

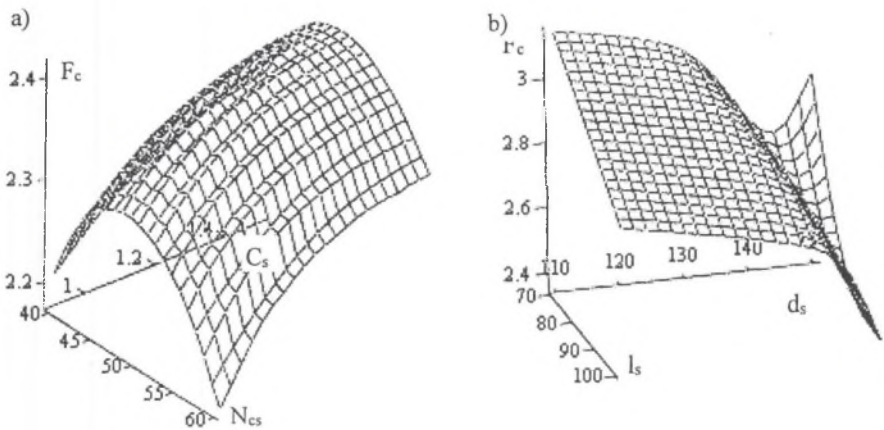
Fig.3. Feasible solution space and contour plots of objective function ($\eta_n \cos \phi_n$) for design parameters (N_{cs} , c_s)



Rys.4. Wykresy warstwiczne (a) oraz odpowiadający im wykres przestrzenny ogólnej funkcji celu F_c dla dwóch zmiennych decyzyjnych (N_{cs} , l_s)

Fig.4. Contour plots (a) and surface plot (b) of objective function F_c for two design parameters (N_{cs} , l_s)

Na rys.4÷5 przedstawiono wykresy przestrzenne ogólnej funkcji celu dla następujących par zmiennych decyzyjnych: (N_{cs}, l_s) , (N_{cs}, c_s) , (l_s, d_s) . Stwierdzono, że funkcja celu najczęściej nie posiada maksimum w zbiorze rozwiązań dopuszczalnych. Rozwiązanie zadania optymalizacji występuje więc zwykle na granicy tego zbioru. W tym tkwi dodatkowa trudność znalezienia prawidłowego rozwiązania zadania optymalizacji metodami deterministycznymi.



Rys.5. Wykresy przestrzenne ogólnej funkcji celu F_c dla dwóch par zmiennych decyzyjnych:

a) (N_{cs}, c_s) ; b) (l_s, d_s)

Fig.5. Surface plots of objective function F_c for two pairs of design parameters a) (N_{cs}, c_s) ; b) (l_s, d_s)

3. FUNKCJONOWANIE ALGORYTMU GENETYCZNEGO

Algorytmy genetyczne są heurystyczną techniką obliczeniową bazującą na procesie ewolucyjnym podobnym do selekcji naturalnej, krzyżowania i mutacji obserwowanej w systemie biologicznym. Funkcja przystosowania jest miarą adaptacji indywidualnej chromosomu do ich środowiska. AG działają na wielkościach dyskretnych, nie na liczbach rzeczywistych, lecz zakodowanych, tworząc łańcuch binarny (chromosom). Chromosomy są więc reprezentowane przez skończoną długość łańcucha utworzonego z 0 i 1. Każda zmienna rzeczywista na pewnym etapie obliczeń musi zostać zakodowana do postaci binarnej oraz przy obliczeniach funkcji przystosowania - odkodowana. do postaci rzeczywistej. Kodowanie powoduje więc dyskretyzację parametrów. Można tak dobrać liczbę bitów i przedział zmiennej, że np. liczba zwojów w zezwoju będzie przyjmować tylko wartości całkowite.

Przy **kodowaniu** najczęściej jest stosowane liniowe odwzorowanie liczby z przedziału $[a_i, b_i]$ w zadany przedział $[0, 2^n - 1]$. Dla każdej zmiennej x_i zakłada się liczbę znaczących

cyfr dziesiętnych l_{di} . Dany przedział zmiennej $x_i - [a_i, b_i]$ należy podzielić na $10^{l_{di}}$ podprzedziałów, przy czym musi być spełniony warunek:

$$(b_i - a_i)10^{l_{di}} \leq 2^{m_i} - 1 \tag{4}$$

gdzie:

m_i - najmniejsza liczba całkowita spełniająca powyższy warunek oznacza równocześnie długość łańcucha binarnego dla tej zmiennej.

Całkowita długość chromosomu (długość łańcucha odpowiadająca wszystkim zmiennym decyzyjnym):

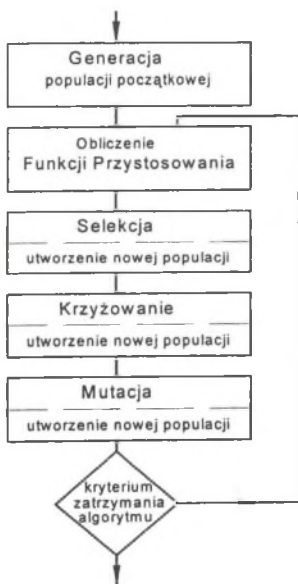
$$m = \sum_i m_i \tag{5}$$

Znając wartość zmiennej x_i w postaci łańcucha binarnego o długości m_i , do jej **odkodowania** należy zastosować wzór:

$$x_i = a_i + \frac{decimal(lan_2)(b_i - a_i)}{2^{m_i} - 1} \tag{6}$$

gdzie:

$decimal(lan_2)$ - oznacza dziesiętną wartość łańcucha binarnego.



Rys.6. Schemat blokowy algorytmu genetycznego
Fig.6. Flowchart of the genetic algorithm

Algorytmy genetyczne wymagają określenia schematu postępowania, jego parametrów, funkcji przystosowania i zasady zatrzymania algorytmu. Zbieżność populacji do globalnego optimum uzyskuje się stosując sekwencyjnie trzy operatory genetyczne: selekcję, krzyżowanie i mutację. Prawdopodobieństwo krzyżowania p_c i prawdopodobieństwo mutacji p_m są dobierane w zależności od rodzaju rozwiązywanego problemu. Schemat blokowy algorytmu genetycznego przedstawia rys.6. W spotykanych publikacjach stosuje się wiele różnych operatorów **selekcji** (np. ruletki, uszeregowania, elitaryzmu, turniejowy, losowy), **krzyżowania** (np. jednopunktowy, dwupunktowy, jednorodny, arytmetyczny, heurystyczny), **mutacji** (np. bit przełączający, brzegowy, nierównomierny, równomierny).

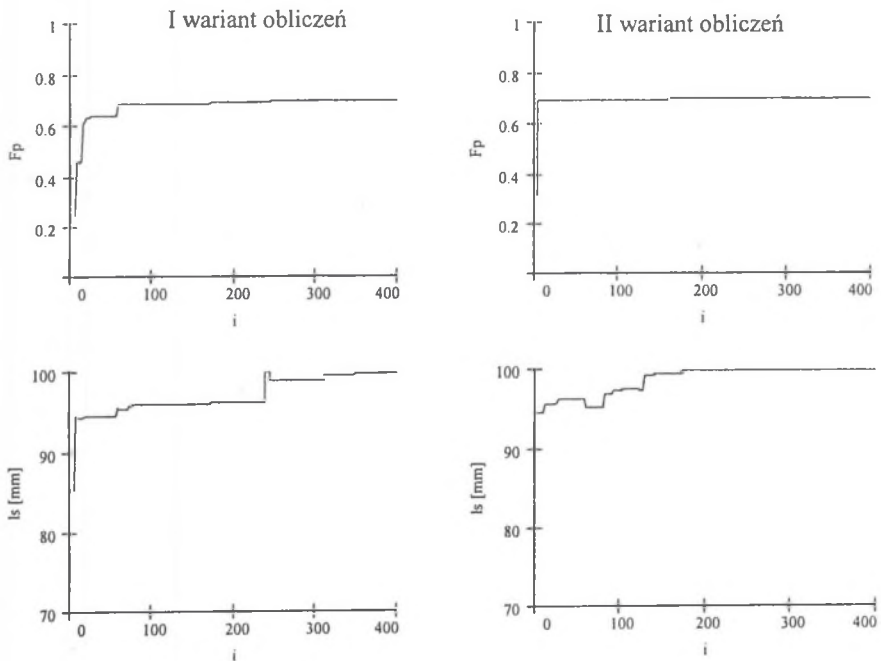
W opracowanym programie zastosowano: kodowanie liniowe, operator ruletkowy selekcji oraz przyjęto zasadę elitaryzmu (zachowania najlepszego


chromosomu) dla kolejnych etapów algorytmu genetycznego. Jako kryterium zatrzymania algorytmu przyjęto zadaną liczbę generacji.

Rozmiar populacji i długość łańcucha chromosomu m jest zależna od liczby przyjętych zmiennych decyzyjnych oraz założonej liczby znaczących cyfr dla każdej zmiennej.

4. WYNIKI OBLICZEŃ OPTYMALIZACYJNYCH

Rys. 7 pokazuje przebieg procesu obliczeniowego dla dwóch wariantów uruchomień programu, dla wskaźnika energetycznego ($\eta_N \cos\varphi_N$) jako funkcji celu, przy tych samych parametrach AG. Jak widać z przedstawionych wykresów, proces obliczeniowy za każdym razem (przy tych samych parametrach AG) przebiega inaczej, równocześnie jednak jest procesem zbieżnym. Wyniki końcowe tych obliczeń przedstawione są w tabeli 2.





Rys.7. Przebieg procesu obliczeniowego w kolejnych generacjach dla najlepszego chromosomu i dwóch wariantów obliczeń. Funkcja przystosowania F_p (funkcja celu $\eta_N \cos\varphi_N$), zmienne decyzyjne: l_s , N_{cs} , c_s

Fig.7. Optimization results in the successive generations for the best chromosom and two calculation variants. Fitness function F_p (the objective function $\eta_N \cos\varphi_N$), design parameters: l_s , N_{cs} , c_s

Tabela 1

Parametry AG: populacja - 100, $p_c=0.9$; $p_m=0.02$,
l.generacji - 2000

Zmienne decyzyjne	Funkcja celu kryterium ogólne			
l_s [mm]	85.47	85.00	85.00	74.22
d_s [mm]	125.04	124.07	125.00	126.91
b_{ds} [mm]	7.49	7.51	7.49	8.24
h_s [mm]	18.16	19.38	19.14	16.61
c_s [mm]	1.46	1.50	1.50	1.31
N_{cs} [-]	52	52	52	54
b_{dr} [mm]	10.49	10.31	10.45	10.76
h_r [mm]	12.02	12.00	12.00	12.42
F_p [-]	3.022	3.033	3.027	3.038

Dla analizowanego silnika wykonywano obliczenia dla różnych funkcji celu, przyjmując różne parametry AG i funkcje ograniczeń.

Przykładowe wyniki końcowe obliczeń (4 warianty obliczeniowe) dla 8 zmiennych decyzyjnych i ogólnej funkcji celu, przedstawia tab.1, zaś dla 3 zmiennych decyzyjnych (wybranych przy założeniu takiego samego wykroju blach stojana i wimika) i wskaźnika energetycznego ($\eta_N \cos\varphi_N$) jako funkcji celu, przedstawia tab.2 (3 warianty obliczeniowe). Powyższe wyniki

Tabela 2

Parametry AG: populacja - 50, $p_c=0.9$;
 $p_m=0.02$, l.generacji - 500

Zmienne decyzyjne		Funkcja celu wskaźnik energetyczny η_N $\cos\varphi_N$		
l_s	[mm]	100.000	99.824	99.766
c_s	[mm]	1.233	1.195	1.195
N_{cs}	[-]	53	53	53
F_p	[-]	0.6972	0.6949	0.6949

obliczeń wskazują, że przy zadanej dyskretyzacji zmiennych decyzyjnych (zadanych liczbach bitów dla tych zmiennych) i odpowiednio dużej liczbie generacji, algorytm wykazuje wystarczającą zbieżność z praktycznego punktu widzenia. Zwiększając liczbę generacji zwiększa się prawdopodobieństwo uzyskania rozwiązania globalnego. Z dużym prawdopodobieństwem można przyjąć, że uzyskiwane rozwiązanie były zbliżone do optimum globalnego.

Tabela 3

Parametry AG: populacja - 100, $p_c=0.9$; $p_m=0.02$,
 l.generacji - 1000

Zmienne decyzyjne		Funkcja celu			
		ogólna	dobroć rozruchu	masa	η_N $\cos\varphi_N$
l_s	[mm]	85.47	96.29	70.00	100.00
d_s	[mm]	125.04	119.07	121.24	130.65
b_{ds}	[mm]	7.49	7.00	7.34	9.145
h_s	[mm]	18.16	19.84	20.00	18.26
c_s	[mm]	1.46	1.50	1.21	1.42
N_{cs}	[-]	52	50	59	51
b_{dr}	[mm]	10.49	10.76	9.41	10.64
h_r	[mm]	12.02	13.20	20.58	20.99
Parametry eksploatacyjne silnika					
η_N	[-]	0.844	0.850	0.842	0.877
$\cos\varphi_N$	[-]	0.807	0.807	0.775	0.833
m_{kr}	[-]	3.01	2.99	2.54	2.35
m_r	[-]	2.94	2.91	2.18	1.85
i_r	[-]	5.00	5.01	4.69	5.00
m	[kg]	19.35	22.06	15.72	22.68

Na podstawie uzyskiwanych wyników obliczeń stwierdzono, że dla odpowiednio dobranych współczynników wagowych funkcji kary, poszukiwane rozwiązanie znajduje się zawsze w zbiorze rozwiązań dopuszczalnych.

W tab.3 przedstawiono wyniki końcowe obliczeń optymalizacyjnych silnika przy różnych kryteriach jakości dla 8 zmiennych decyzyjnych.

Tabela zawiera wartości zmiennych decyzyjnych oraz podstawowe parametry eksploatacyjne (m_{kr} - krotność momentu maksymalnego, m_r - krotność momentu rozruchowego, i_r - krotność prądu

rozruchowego, m - masa materiałów czynnych) wariantu optymalnego rozwiązania.

Uzyskane rozwiązania optymalne przy różnych kryteriach jakości odpowiadają interpretacji fizycznej postawionego zadania optymalizacji.

5. WNIOSKI

Pokazano, że program optymalizacyjny bazujący na algorytmie genetycznym jest skutecznym narzędziem do optymalizacji silników indukcyjnych.

W celu uzyskania zadowalającej skuteczności AG należy odpowiednio dobrać parametry tego algorytmu (liczbę populacji, prawdopodobieństwa krzyżowania i mutacji, liczbę generacji). Na podstawie wykonanych obliczeń dla wielu zadanych parametrów AG można stwierdzić, że niezbędna liczba generacji w zależności od postawionego zadania optymalizacji powinna wynosić od kilkuset do kilku tysięcy. Oznacza to, przy złożonym modelu obliczeniowym maszyny, długi czas trwania obliczeń. Zależy on bowiem od liczby generacji i wielkości populacji.

Należy jednak stwierdzić, że w ogólnym przypadku, przy zastosowaniu AG rozwiązanie znajduje się w pobliżu rozwiązania optymalnego.

Wg autorów niektórych publikacji, aby zapewnić większą dokładność rozwiązania, można zastosować metodę deterministyczną, przyjmując jako punkt startowy rozwiązanie uzyskane metodą AG.

LITERATURA

1. Bianchi N., Bolognani S.: Design optimisation of electric motors by genetic algorithms. IEE Proceedings Electric Power Applications, vol.145, No 5, September 1998, str.475÷483.
2. Goldberg D.E.: Algorytmy genetyczne i ich zastosowania. WNT, Warszawa 1995.
3. Jazdzyński W.: Multicriterial optimisation of squirrel-cage induction motor design. IEE Proceedings, vol.136, No 6, November 1989, str.299÷307.
4. Kim M.K., Lee C.G., Jung H.K. Multiobjective optimal design of three-phase induction motor using improved evolution strategy. IEEE Transactions on Magnetics, vol. 34, No 5, September 1998, str.2980÷2983.
5. Michalewicz Z.: Algorytmy genetyczne + struktury danych = programy ewolucyjne. WNT, Warszawa 1996.
6. Oh Y.H., Chung T.K., Kim M.K., Jung H.K.: Optimal design of electric machine using genetic algorithms coupled with direct method. IEEE Transactions on Magnetics, vol. 35, No 3, May 1999, str.1742÷1745.
7. Śliwiński T.: Suboptimal induction motors. Zeszyty Naukowe Pol. Łódz., Elektryka, z.91, Łódź 1998, str.19÷25.
8. Ülter G.F., Mõhammed O.A., Koh C.S.: Design optimization of electrical machines using genetic algorithms. IEEE Transactions on Magnetics, vol. 31, No 3, May 1995, str.2008÷2011.
9. Wieczorek J.P., Göl Ö. Michalewicz Z.: An evolutionary algorithm for the optimal design of induction motors. IEEE Transactions on Magnetics, vol. 34, No 6, November 1998, str.3882÷3887.
10. Wurtz F., Richomme M., Bigeon J., Sabonnadiere J.C.: A few results for using genetic algorithms in the design of electrical machines. IEEE Transactions on Magnetics, vol. 33, No 2, March 1997, str.1892÷1895.

Recenzent: Prof. dr hab. inż. Roman Nadolski

Wpłynęło do Redakcji dnia 5 maja 2000 r.

Abstract

In the paper the possibilities of GA application to optimization of the electromagnetic circuit of a 3-phase induction motor are presented. The problem of optimization of motor electromagnetic circuit is a constrained optimization problem. Figs 1÷2 show results of the motor calculations for two design parameters exemplary contour plots for several constraint functions and the multiobjective function (Fig.2). From them it follows that the feasible solution domain (see dashed area) is not convex.

The used algorithm of electromagnetic calculations of a 3-phase induction motor ($P_n=3$ kW; $f_n=50$ Hz; $U_n=380$ V; $p=2$) is based on the circuit model. It takes into account saturation of the circuit by the main flux and leakage fluxes as well as deep-bar rotor effects. In case of the developed computer program there is possibility of selection of the following independent variables: d_s - stator inner diameter, l_s - stator core length, N_{cs} - number of turns in stator winding coil, c_s - diameter of stator winding conductor, h_s - stator slot depth, b_{ds} - stator tooth width, h_r - rotor slot depth, b_{dr} - rotor tooth width.

It is possible to select the following objective functions in the developed program: minimum mass of active materials of winding and core, maximum energetic factor, maximum quality factor at the locked rotor, multiobjective criterion (1) containing the mentioned above partial criteria.

GAs require determination of the strategy, specification: of the design parameters, of the objective function and the algorithm stopping criterion. The convergence of the population to the global optimum is obtained using sequentially three genetic operators: selection, crossover, mutation (Fig.5). The population size, the chromosome string length (bit number), the crossover probability p_c , and the mutation probability p_m are selected in dependence on the kind of a solved problem. The constraints have been taken into account in the program using the method of the external penalty function (3).

The exemplary calculations process in the successive generations for the objective function and three variables l_s is presented in Fig.6.

The results of optimization calculations for the multiobjective function are presented in the Tab.1 and for different quality criteria in the Tab.2.

Basing on the performed calculations for many given parameters of GA one can state that the necessary number of generations is several thousand. The program at each run found solutions included in the feasible space. One can state with high probability that the obtained solutions are close to the global optimum

It has been proved that the optimization program basing on GA is potent tool for induction motor optimization. To obtain the satisfactory efficiency of GA one should appropriately select parameters of this algorithm.