

Jan Anuszczyk, Piotr Błaszczuk
Politechnika Łódzka, Łódź


STRATEGIE EWOLUCYJNE W OPTYMALIZACJI SILNIKÓW ZWARTOBIEGUNOWYCH

THE EVOLUTIONARY STRATEGIES IN OPTIMIZATION OF SHADED-POLE MOTORS

Abstract: An optimization module was built on the basis of MATLAB and FEMM packages where the above-described objective function, searching the maximum starting torque in a shaded-pole induction motor, was implemented. In the process of optimization functions of genetic algorithms introduced in MATLAB [4], were implemented. Thus, an initial population in the form of six chromosomes was defined. The genetic algorithm enables to keep an equilibrium between wide research of the solution space and using the solutions found due to the previous generations of chromosomes. The objective function was defined so that good solutions meeting the pre-set limitations were reproduced and other solutions were rejected by means of a selection method in every subsequent generation. On completing calculations, the final population was the next initial population until the pre-set convergence of consecutive results was achieved.

1. Wstęp

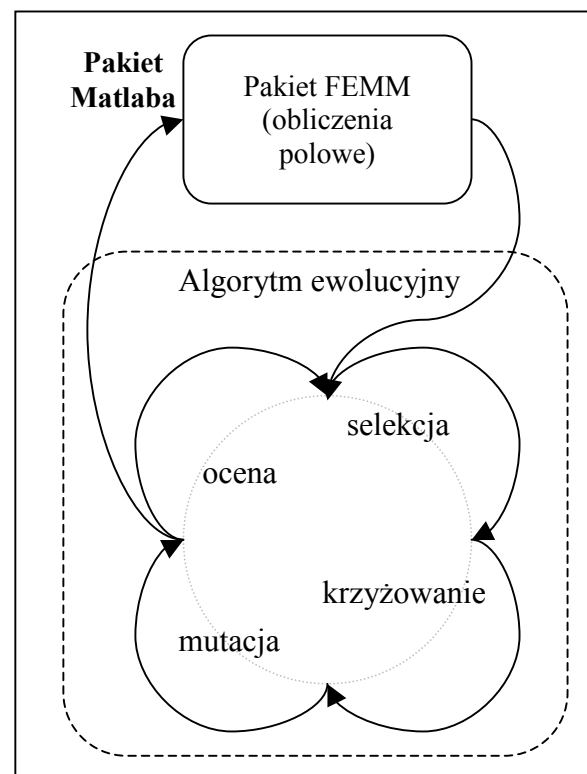
Jednym z najbardziej przydatnych środowisk obliczeniowych do analizy skomplikowanej geometrii badanego obiektu jest metoda elementów skończonych (MES). Stanowi ona



Rys. 1. Optymalizowana przestrzeń rozwiązań z narzuconymi ograniczeniami w badanym silniku zwartobiegunowym

podstawowe narzędzie służące do obliczeń i jednocześnie symulacji rozkładu natężenia pola, indukcji magnetycznej czy też głębokości wnikania strumienia magnetycznego w obwodach elektromagnetycznych przetworników. Przetwarzanie wyników otrzymanych z obliczeń polowych umożliwia wyznaczanie parametrów eksploatacyjnych badanych przetwor-

ników i stanowi podstawę dla obliczeń optymalizacyjnych. W procesie optymalizacji istotną rolę odgrywa dobór zmiennych sterujących procesem optymalizacji, ponieważ przy dużej liczbie zmiennych następuje znaczne wydłużenie czasu obliczeń, co wpływa na zmniejszenie efektywności procesu.




Rys. 2. Schemat algorytmu ewolucyjnego zaimplementowanego w Matlabie

Należy zatem uwzględniać rodzaj zmiennych, które w zasadniczy sposób wpływają na proces optymalizacji badanego przetwornika. Porównując dokładność działania strategii ewolucyjnych do algorytmów ewolucyjnych, należy brać pod uwagę również czas obliczeń. Odwołując się do klasycznych operatorów genetycznych, bazowały one na wektorach binarnych w przeciwieństwie do strategii ewolucyjnych gdzie używa się reprezentacji zmiennopozycyjnej. Wprowadzenie do strategii ewolucyjnych operatora krzyżowania, istotnego z punktu widzenia penetracji przestrzeni poszukiwań, powoduje że ztraca się granica pomiędzy strategiami i algorytmami ewolucyjnymi. Na rys. 1 oraz 2 przedstawiono strukturę badanego obiektu oraz schemat ideowy algorytmu ewolucyjnego [1], [3].

2. Algorytm ewolucyjny z kodowaniem binarnym

Zaimplementowany algorytm ewolucyjny uwzględnia kodowanie binarne, w którym allele wszystkich genów w chromosomie są równe 0 lub 1. Dany gen czyli allel, jest określany jako wartość cechy, czy też wariant genu. Zastosowane kodowanie, często prowadzi do znacznych utrudnień w realizacji końcowego rozwiązania. Problem ten został przetestowany w niniejszej pracy, rys. 3.



Rys. 3. Krzywa $F_p=f(L_p)$ zmian wartości funkcji przystosowania w funkcji liczby populacji - kodowanie binarne

Algorytm optymalizacyjny z kodowaniem binarnym dochodził do rozwiązania pośredniego, definiując maksimum lokalne, dla którego wartość otrzymanego momentu optymalizowanego silnika była na poziomie $M_r=0,8 \times 10^{-3} \text{ Nm}$. Dodatkowy problem, który się pojawia w tego typu optymalizacji, to krawędzie Hamminga. Wynika on z odległości pomiędzy dwoma chromosomami, w których różna jest

liczba mutacji bitowych potrzebnych do przekształcenia jednego chromosomu w drugi. Zastosowanie algorytmu ewolucyjnego z kodowaniem binarnym powoduje, że porusza się on w ograniczonej strukturze, w sąsiedztwie punktów stanowiących poprawne rozwiązanie zadania optymalizacji numerycznej. Kodowanie to w przypadku rozwiązywanego zadania prowadzi do osiągnięcia przez algorytm optimum lokalnego, a zatem błędnego kierunku poszukiwania rozwiązania, [2].

3. Algorytm ewolucyjny z kodowaniem zmiennopozycyjnym

Uwzględniając założenia strategii ewolucyjnych, zdefiniowano środowisko obliczeniowe na podstawie funkcji celu i funkcji ograniczających. Kod genetyczny dobrano tak, aby zachować proporcje odległości w przestrzeni fenotypu i genotypu. Zdefiniowano odpowiednio parametr x jako punkt w przestrzeni fenotypu, F jako funkcję dekodującą oraz X jako punkt w przestrzeni genotypu, gdzie zachodzi:

$$x = F(X) \quad (3.1)$$

Zastosowane kodowanie uwzględnia potrzeby algorytmu ewolucyjnego tak dobrane, aby zachodziły następujące zależności:

$$\forall x \quad \exists X \quad F(X) = x \quad (3.2)$$

co oznacza, że dla każdego x , istnieje genotyp X , opisany funkcją dekodującą $F(X)$, opisaną powyżej. Jeśli w rozważanym przypadku

$$|x^1 - x^2| \geq |x^1 - x^3| \quad \text{to} \quad |X^1 - X^2| \geq |X^1 - X^3| \quad (3.3)$$

to uwzględniając właściwość (3.2) można stwierdzić, że każde rozwiązanie zadania optymalizacyjnego można przedstawić jako genotyp, natomiast zależność (3.3) zapobiega powstawaniu dodatkowych maksimów lokalnych funkcji przystosowania. Na podstawie przedstawionej wyżej oceny doboru metody kodowania do ściśle zdefiniowanego zadania optymalizacji silnika zwartobiegunowego SFZ, wybrano metodę kodowania rzeczywistoliczbowego, [2]. Korzystnym elementem przy ocenie metody kodowania była analiza testowa zastosowanego algorytmu optymalizacyjnego. Stwierdzono, że bardziej pożądane cechy kodowania chromosomów uzyskano dla kodowania rzeczywistoliczbowego w zapisie zmiennopozycyjnym. W kodowaniu tym każdy wektor chromosomu koduje się jako wektor liczb

zmiennopozycyjnych, o takiej samej długości jak wektor rozwiązania. Najczęściej dokładność takiego kodowania, jest również znacznie wyższa od kodowania binarnego.

W obliczeniach optymalizacyjnych często zdarza się sytuacja, że rozwiązanie optymalne znajduje się na granicy obszaru dopuszczalnego, w punkcie leżącym na powierzchni jednej z funkcji ograniczających. W przedstawionym rozwiązaniu silnika SFZ, funkcja optymalizacyjna znajduje rozwiązanie leżące na przecięciu kilku powierzchni ograniczających. Na podstawie takiego rozwiązania można stwierdzić poprawność zastosowanego algorytmu, ponieważ nie ma niebezpieczeństwa osiadania w maksimach lokalnych, które nie są rozwiązaniem końcowym. Najczęściej stosowane metody uwzględniające ograniczenia w zadaniach optymalizacji to: zadana funkcja kary, algorytm naprawy (mający za zadanie poprawę powstałego rozwiązania niedopuszczalnego) oraz eliminacja rozwiązań niedopuszczalnych. W pracy zaimplementowano metodę uwzględnienia ograniczeń poprzez zewnętrzną funkcję kary, zależność (3.4).

$$P(x) = \sum_{i=1}^n w_i * (p_i(x)) \quad (3.4)$$

gdzie:

w_i - jest współczynnikiem wagowym kary,
 $p_i(x)$ - wartością kolejnej funkcji ograniczeń odniesioną do wartości ograniczenia,

g_i - jest zadaną wartością dla i -tej funkcji ograniczeń,

$g_i(x)$ - jest wartością i -tej funkcji ograniczeń dla zmiennych zawartych w osobniku x .

Przyjmowane wartości funkcji ograniczeń są następujące:

$$p_i(x) = \begin{cases} 0 & \text{dla } g_i(x) \leq 0 \\ \frac{|g_i(x) - g_i|}{g_i} & \text{dla } g_i(x) > 0 \end{cases} \quad (3.5)$$

Rozwiązania dopuszczalne silnika zostały ograniczone przez zbiór funkcji ograniczających. Dla zadania optymalizacji strefy bocznika magnetycznego zdefiniowano ograniczenia kosztowe przyjmujące postać:


$$l_i \leq x_i \leq u_i \quad (3.6)$$

Przy czym liczby l_i i u_i ograniczają z dołu i z góry wartości, które przyjmuje zmienna niezależna x_i , kolejno dla sześciu zmiennych decy-


zyjnych sterujących procesem optymalizacji. Dla dwóch zmiennych decyzyjnych odpowiedzialnych za optymalizację strefy nierównomiernej szczeliny powietrznej przyjęto ograniczenie wyrażone funkcją liniową:

$$g_i(x) = ax + b \quad (3.7)$$


Przy czym a zdefiniowano jako współczynnik kierunkowy, natomiast b jako stałą funkcji.




Rys. 4. Krzywa $F_p=f(L_p)$ zmian wartości funkcji przystosowania w funkcji liczby populacji (dla procesu: 30 osobników i 200 populacji)



Rys. 5. Charakterystyki funkcji przystosowania $F_p=f(L_p)$ w funkcji liczby populacji dla różnej liczby osobników w populacji: 20, 30 i 40



Rys. 6. Krzywa $D1=f(L_p)$ dla obliczeń wg wariantu IIc (krzyżowanie heurystyczne, mutacja brzegowa); końcowe parametry procesu to 40 osobników i 300 populacji



Rys. 7. Krzywa $F_p=f(L_p)$ funkcji przystosowania dla obliczeń wg wariantu IIc i optymalnego rozwiązania SFZ (krzyżowanie heurystyczne, mutacja brzegowa), końcowe parametry procesu to 40 osobników i 300 populacji

Ilustracje przeprowadzonych testów w odniesieniu do funkcji przystosowania podano na rysunkach 4, 5, 6 i 7.

4. Podsumowanie

Przeprowadzony proces optymalizacyjny uwzględnia szerokie spektrum operatorów genetycznych, zastosowanych kolejno w dwóch przypadkach kodowania - binarnego i zmiennopozycyjnego. Zdefiniowanie odpowiedniej strategii w sensie ustawiania ważności poszczególnych operatorów genetycznych, stanowi najważniejszy element procesu optymalizacyjnego. Wyłonienie odpowiednich operatorów, na podstawie analizy zadanych funkcji testowych, powoduje znaczne skrócenie czasu obliczeń optymalizacyjnych. Proces poszukiwania został ukierunkowany na maksymalizację momentu silnika indukcyjnego zwartobiegunowego. Strategia z kodowaniem binarnym zakłada dwa warianty optymalizacyjne Ia i Ib, na podstawie których stwierdzono, że najlepsze rozwiązanie jest osiągane dla algorytmu ewolucyjnego o liczbie osobników 40 i liczbie populacji 300. Jednym z kluczowych warunków poprawnej optymalizacji jest prowadzenie wielu równoległych obliczeń optymalizacyjnych w celu osiągnięcia powtarzalnego rozwiązania końcowego. Przy kodowaniu binarnym zauważono wyraźne osiadanie algorytmu w sąsiedztwie rozwiązań lokalnych, co było przyczyną przyjęcia strategii z kodowaniem zmiennopozycyjnym w ostatecznej wersji algorytmu ewolucyjnego. Do analizy optymalizacyjnej z kodowaniem zmiennopozycyjnym wyłoniono ostatecznie trzy strategie z określoną kombinacją operatorów genetycznych, IIa, IIb i IIc. Na podstawie

przyjętego schematu obliczeń optymalizacyjnych uzyskano rozwiązanie globalne w przestrzeni poszukiwań określonej przez przyjęte funkcje ograniczające - strategia IIc. Przeprowadzony proces optymalizacyjny udowadnia, że:

1. Strategia z kodowaniem zmiennopozycyjnym przy odpowiedniej kombinacji operatorów genetycznych pozwala na uzyskanie optimum globalnego.
2. Zrównoważony nacisk selektywny pozwala na poprawne działanie algorytmu ewolucyjnego i skuteczną optymalizację.
3. Najbardziej stabilny przebieg procesu optymalizacyjnego zapewnia wariant z krzyżowaniem heurystycznym i mutacją brzegową.
4. Wyłonienie rozwiązania globalnego optymalizowanego silnika, dającego wartość momentu rozruchowego $M_r=1,464 \times 10^{-3} \text{ Nm}$ zostało zweryfikowane metodą obliczeń polowych.

5. Literatura

- [1]. Anuszczyk J., Błaszczuk P.: Field analysis and magnetic core optimisation for an induction micro-motor with short-circuit auxiliary phase. Proceedings of 15th Symposium on Micromachines and Servosystems – MiS'2006. Soplicowo, Poland, September 17-21, 2006.
- [2]. Błaszczuk P.: Optymalizacja strefy szczelinowej silnika indukcyjnego z fazą zwartą przy wykorzystaniu algorytmów ewolucyjnych, Praca doktorska 2009.
- [3]. Błaszczuk P.: Optymalizacja silnika indukcyjnego z fazą zwartą, IV Ogólnopolskie Warsztaty Doktoranckie OWD 2002, Istebna-Zaolzie 2002.
- [4]. Matlab The Language of Technical Computing, version 7.0.4.365 (R14) January 29, 2005.

Autorzy

Dr hab. Jan Anuszczyk prof. PŁ, kierownik Zakładu Transportu i Przetwarzania Energii Instytutu Elektroenergetyki Politechniki Łódzkiej.

Dr inż. Piotr Błaszczuk, adiunkt w Zakładzie Transportu i Przetwarzania Energii Instytutu Elektroenergetyki Politechniki Łódzkiej.