

DOI: 10.5604/20830157.1130178

## PRZEGLĄD WYBRANYCH METOD EWOLUCYJNYCH W OPTYMALIZACJI WIELOKRYTERIALNEJ

**Michalina Gryniewicz-Jaworska**

Politechnika Lubelska, Wydział Elektrotechniki i Informatyki, Instytut Informatyki

**Streszczenie.** Od połowy lat osiemdziesiątych nastąpił rozwój metod, które bazują na nowym sposobie tworzenia rozwiązań niezdominowanych. Prowadzą one do wyznaczenia frontu ocen Pareto naśladując mechanizmy wytworzone w świecie mikro- i makro- przyrody. Aktualnie do istniejących metod optymalizacji zaliczyć możemy: algorytmy genetyczne, ewolucyjne, algorytmy stosujące sztuczne systemy immunologiczne, algorytmy rojowe oraz mrówkowe. W artykule zaprezentowano kilka wybranych metod optymalizacji ewolucyjnej, w tym algorytm ewolucyjny, mrówkowy, rojowy oraz NSGA. Ponadto opisano sposób działania poszczególnych algorytmów oraz ich przykładowe zastosowanie.

**Słowa kluczowe:** optymalizacja wielokryterialna, optymalizacja ewolucyjna, algorytmy genetyczne, sztuczne systemy immunologiczne

### AN OVERVIEW OF EVOLUTIONARY METHODS OF MULTI-CRITERIA OPTIMIZATION

**Abstract.** Since the mid-eighties we can see the development of methods that are based on a new method of creating dominated solutions. They lead to designate the ratings Pareto front mimicking the mechanisms created in the world of micro and macro-nature. Currently, the existing optimization methods can include: genetic algorithms, evolutionary algorithms using artificial immune systems, swarm and formic algorithms. The article presents few selected evolutionary optimization methods, including evolutionary algorithm, formic and swarm algorithms, and NSGA. The article also describes how the different algorithms work and their exemplary application

**Keywords:** multi-criteria optimization, evolutionary optimization, genetic algorithms

### Wstęp

Optymalizację wielokryterialną można zdefiniować w najprostszy sposób w odniesieniu do optymalizacji jednokryterialnej, gdzie funkcja celu zawsze zwróci nam jedną wartość. Jednak nieraz będziemy mieli do czynienia z sytuacją kiedy trzeba będzie sformułować zadanie z wieloma kryteriami, które nieraz są trudno ze sobą porównywalne a nawet sprzeczne. Na przykład, w przypadku zakupu dowolnego urządzenia będziemy rozważać zbiór różnych kryteriów, takich jak: koszt zakupu urządzenia, czas dostawy, długość okresu gwarancyjnego, koszty eksploatacji, niezawodność, jakość wykonywanych prac oraz dostępność serwisu i części zamiennych. Należy zwrócić uwagę, że część z tych kryteriów będziemy chcieli minimalizować, czyli: koszt zakupu, czas dostawy czy koszty eksploatacyjne, natomiast niektóre z nich będziemy maksymalizować, na przykład długość okresu gwarancyjnego lub jakość wykonywanych prac. Warto także dodać, że rozpatrywane kryteria posiadają różne jednostki, część z nich wyrażana jest w złotych, część w miesiącach a niektóre z nich określone są przez wartości werbalne (np. dobra, niewystarczająca jakość).

Nasuwają się więc dwa podstawowe pytania, jak ocenić równoczesny wpływ wszystkich kryteriów na ostateczną decyzję oraz czy interesuje nas znalezienie jednego konkretnego rozwiązania, czy też może podzbiór rozwiązań, z których każde będzie się różniło, lecz w pewien sposób będzie optymalne?

### 1. Optymalizacja wielokryterialna

W przypadku zadań z wieloma kryteriami możemy skorzystać z tradycyjnych metod optymalizacji. Często stosowanym rozwiązaniem jest agregacja różnych kryteriów w jedną funkcję celu, która zawsze zwróci nam jedną wartość, co pozwala na wygenerowanie rankingu rozpatrywanych wariantów. Zazwyczaj nie ma jasno ustalonych przesłanek, którą metodą agregacji należy zastosować, czy będzie to średnia arytmetyczna, ważona średnia arytmetyczna, średnia geometryczna czy też ważona średnia geometryczna. Można zastosować również metody, w których co prawda nie stosujemy agregacji, ale zamieniamy zadanie z wieloma kryteriami na ciąg zadań jednokryterialnych. Pamiętając, że kryteria oceny reprezentują różne wielkości fizyczne i ekonomiczne wyrażone w różnych jednostkach można próbować przejść na wielkości bezwymiarowe, ale czy w takim przypadku istnieje metodologiczne uzasadnienie aby dodawać do siebie wartości

reprezentujące pierwotnie różne wielkości. Rezygnacja z optymalizacji wielokryterialnej na rzecz jednokryterialnej prowadzi do utraty początkowych informacji o rozwiązywanym problemie. Właściwym rozwiązaniem jest pozostanie przy optymalizacji wielokryterialnej.

#### 1.1. Rozwiązania zdominowane i niezdominowane

Włoski uczony Vilfredo Pareto na przełomie XIX i XX wieku wykazał, że w optymalizacji wielokryterialnej można mówić o dwóch podziorach rozwiązań: zdominowanych oraz niezdominowanych. Według Pareto nie ma jednoznacznej odpowiedzi, istnieje natomiast grupa rozwiązań korzystniejszych od pozostałych i określił je jako rozwiązania niezdominowane [4].

Rozwiązanie niezdominowane to takie, którego nie jesteśmy w stanie polepszyć ze względu na żadne z obowiązujących kryteriów bez pogarszania równocześnie wartości któregośkolwiek z pozostałych kryteriów[5].

Dla zadania minimalizacji zestawu  $k$  funkcji celu

$$\mathbf{f}(\mathbf{x}) = (f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_k(\mathbf{x}))$$

rozwiązanie  $\hat{\mathbf{x}}$  jest zdominowanym, jeśli istnieje dopuszczalne rozwiązanie  $\tilde{\mathbf{x}}$  nie gorsze niż  $\hat{\mathbf{x}}$ , tzn. dla każdej funkcji celu  $f_i(\tilde{\mathbf{x}})$ ,  $i=1, \dots, k$ . W przeciwnym wypadku rozwiązanie takie nazywamy rozwiązaniem niezdominowanym lub optymalnym w sensie Pareto (paretooptymalne).

### 2. Ewolucyjne metody optymalizacji


Od połowy lat osiemdziesiątych nastąpił rozwój metod, które bazują na odrębnym, różniącym się od tradycyjnym metod sposobie tworzenia rozwiązań niezdominowanych, które prowadzą do wyznaczenia frontu ocen Pareto. Metody te nazywane są metodami ewolucyjnymi i polegają na tym, że w wirtualnym świecie obliczeń komputerowych naśladują mechanizmy wytworzone w rzeczywistym świecie, mikro- i makro- przyrody. Wśród tych metod możemy wyróżnić: algorytmy ewolucyjne, genetyczne, rojowe, mrówkowe oraz algorytmy stosujące sztuczne systemy immunologiczne.

#### 2.1. Algorytmy ewolucyjne

Aktualnie mimo dużej popularności tradycyjnych metod optymalizacji wykorzystuje się do rozwiązywania zadań algorytmy ewolucyjne, które w wielu przypadkach dużo lepiej sprawdzają się w przypadku dużej liczby rozwiązań w sensie Pareto.

Zadaniem algorytmu ewolucyjnego jest przeszukanie przestrzeni alternatywnych rozwiązań w celu wybrania najlepszych lub potencjalnie najlepszych. Przeszukiwanie odbywa się z wykorzystaniem mechanizmów ewolucji oraz doboru naturalnego. Zasada działania algorytmu ewolucyjnego polega na przetwarzaniu populacji osobników, z których każdy jest propozycją rozwiązania konkretnego zadania. Każdy osobnik posiada przyporządkowaną wartość, nazywaną przystosowaniem osobnika, ponadto wyposażony jest w genotyp, gdzie na jego podstawie tworzony jest fenotyp. Proces zamiany genotypu na fenotyp nazywany kodowaniem [3].

Sposób działania algorytmu polega na wielokrotnym wykonaniu pętli, w której następują po sobie: reprodukcja, operacje genetyczne, ocena oraz sukcesja, co pokazano na rys. 1.



Rys. 1. Schemat algorytmu ewolucyjnego [7]

Na podstawie genów osobnika liczona jest funkcja oceny. Pełni ona rolę środowiska, w którym „istnieją” osobniki i określa, jaki jest konkretny osobnik. W każdym pokoleniu tworzony jest zbiór nowych osobników, ponadto nowy osobnik generowany jest na podstawie jednego lub więcej osobników z populacji, poprzez działanie operatora mutacji lub krzyżowania. Osobniki, na podstawie których generowane jest nowe rozwiązanie, nazywane są osobnikami rodzicielskimi, a nowy osobnik (osobniki) nazywany jest osobnikiem potomnym lub dzieckiem. Zbiór ten dołączony zostaje do populacji. Populacja oraz zbiór nowych osobników stanowią bazę, z której wybierane są kolejne osobniki do nowej populacji. Wybór osobników do nowej populacji odbywa się dzięki operatorowi selekcji.

Istnieje wiele metod selekcji osobników, do najczęściej stosowanych wyróżnić możemy: selekcję turniejową, rankingową, metodę ruletki oraz selekcję elitarną [2].

Selekcja elitarna polega na posortowaniu osobników od najlepiej przystosowanych do najsłabszych i zatrzymaniu tylko grupy osobników określonych przez funkcję. Pozostała część osobników jest odrzucana i nie bierze udziału w kolejnych operacjach genetycznych [1].


## 2.2. Algorytm mrówkowy (Ant Colony Optimization)

Algorytm ten został opracowany przez Marco Dorigo na potrzeby jego pracy doktorskiej. Często wykorzystywany jest do rozwiązywania zagadnień związanych z wyszukiwaniem najkrótszych ścieżek w grafie.

Autor algorytmu czerpał inspiracje ze świata mrówek gdyż one są w stanie wybrać najkrótszą trasę między mrowiskiem a pożywieniem. Mrówki kierując się w stronę pożywienia wybierają swoją trasę losowo, w drodze powrotnej pozostawiając ślad feromonowy. Feromony jednak parują dlatego mrówki starają się wybrać krótszą trasę. W przypadku gdy znajdą taką trasę pozostałe mrówki korzystają z niej chętniej pozostawiając przy tym wzmocniony ślad feromonowy.

Na rysunku 2 przedstawiono schemat wyboru trasy przez mrówki. W pierwszej podróży (a) pojedyncza mrówka wybiera

swoją trasę losowo, w drodze powrotnej pozostawiając ślad feromonowy. Następnie (b) kolejne mrówki wybierają trasę podążając za śladem feromonowym swojej poprzedniczki. Mrówki poszukując pożywienia starają się wybrać jak najkrótszą trasę, tym samym w drodze powrotnej pozostawiając wzmocniony ślad feromonowy. Na rysunku (c) zaprezentowany jest wybór najkrótszej ścieżki przez mrówki, brak uczęszczania pozostałymi ścieżkami spowoduje wyparowanie feromonu, tym samym mrówki przestaną poruszać się tymi ścieżkami.



Rys. 2. Schemat wyboru trasy przez mrówki [9]

Algorytm mrówkowy wykorzystywany jest do wyszukiwania najkrótszych ścieżek w grafie i został zastosowany do rozwiązania problemu komiwojażera.

Opis ogólnego algorytmu rozwiązania problemu komiwojażera z wykorzystaniem *Algorytmu mrówkowego*.

### 1. Start

Oszacowanie początkowego poziomu feromonu na krawędziach grafu.

### 2. Powtarzaj

Odparowanie porcji feromonu ze wszystkich krawędzi.

Wylosowanie miast początkowych i stworzenie ścieżek dla wszystkich mrówek na podstawie aktualnego poziomu feromonu na krawędziach grafu.

Naniesienie feromonu na krawędzie w ilościach wynikających z długości ścieżek wyznaczonych przez mrówki.

aż do (warunek);

### 3. Stop

Algorytm mrówkowy stosowany jest do rozwiązywania skomplikowanych obliczeniowo zadań, gdzie zastosowanie precyzyjnych metod nie przynosi zadowalających efektów. Sprawdzają się w przypadku gdy szukamy dobrego rozwiązania a nie najlepszego[8].

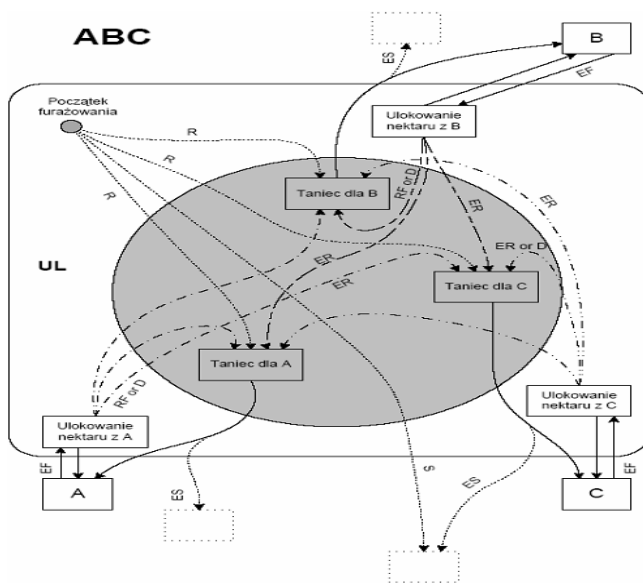
## 2.3. Algorytmy rojowe (Particle Swarm Optimization)

Kennedy i Eberhart zainspirowani stadem zwierząt (owady, ptaki, ryby) na podstawie obserwacji stworzyli probabilistyczną technikę optymalizacji. Według autorów w/w teorii o sile gatunku stanowi społeczność złożona z kilku osobników, których sposób zachowania można zapisać w prosty sposób. Osobniki wykonują określone czynności jednocześnie komunikując się ze sobą w ustalony sposób, można powiedzieć, że dzielą się wiedzą między sobą. Zaobserwowano kilka prostych zasad zachowania osobników:

- jednorodność, każdy osobnik ma z góry określony model zachowania, każdy może zostać liderem,
- lokalność, tylko najbliższe osobniki mają wpływ na zachowanie pojedynczego osobnika,
- unikanie kolizji z osobnikami w okolicy,
- dostosowanie prędkości do osobników, które są w okolicy,
- centrowanie stada, trzymanie się w odpowiedniej bliskości w stosunku do innych osobników [6].

Na rysunku 3 przedstawiono schemat zdobywania pożywienia przez pszczoły. Komunikacja między pszczołami odbywa się poprzez taniec wirowy. Pszczoły dzielą się informacjami

proporcjonalnie do zasobu źródła, im zasobniejsze źródło pożywienia tym więcej pszczoł będzie z niego korzystało.



Rys. 3. Schemat zdobywania pożywienia przez pszczoły [6]

Algorytmy rojowe są najczęściej stosowane w optymalizacji numerycznej oraz wykorzystywane są do kontroli pojazdów bezzałogowych, ponadto mają zastosowanie w przypadku kontroli nanobotów wewnątrz ciała zaatakowanego nowotworem.

Inteligencja roju zyskała popularność ze względu na niskie koszty obliczeniowe oraz prosty algorytm matematyczny [6].

#### 2.4. Algorytm NSGA (Nondominated Sorting Genetic Algorithm)


Metoda ta opiera się na koncepcji Goldberga z 1989 roku i koncentruje się na podziale osobników w podpopulacje, uwzględniając ich rangi. Aby zagwarantować różnorodność populacji stosuje się dzielenie sztucznej funkcji przystosowań. Wyrzadzając proces selekcji istniejąca populacja szeregowana jest pod względem dominacji. Wszystkie osobniki niezdominowane kwalifikuje się do pierwszego frontu przyporządkowując im sztuczną wartość funkcji przystosowań, proporcjonalną do liczebności populacji w celu zapewnienia takich samych możliwości reprodukcyjnych. W kolejnych etapach pomija się tę grupę osobników niezdominowanych a pozostałą populację poddaje się takiemu samemu mechanizmowi wyodrębniając kolejną warstwę rozwiązań niezdominowanych (front 2, front 3 itd.). Utworzonym zbiorom osobników przyporządkowuje się nowe wartości sztucznego przystosowania.

Proces ten trwa do momentu sklasyfikowania całej populacji.

Na rysunku 4 przedstawiono przykładową selekcję w algorytmie NSGA. Przyjmuje się zasadę, że im mniejsza liczba określająca front tym rozwiązanie jest ważniejsze i częściej bierze udział w procesie krzyżowania przy generowaniu nowych populacji.

W przeświadczeniu Goldberga takie działanie powoduje, że w następnym procesie wyznaczania kolejnej populacji będą mogły być wykorzystywane wszystkie wcześniejsze rozwiązania z uwzględnieniem nadanych wartości przystosowania [7].

Pomimo dobrych wyników omówiony powyżej algorytm nie jest bez wad, jedną z nich jest między innymi duża złożoność obliczeniowa oraz brak selekcji elitarniej, która usprawnia działanie algorytmu ewolucyjnego [8].



Rys. 4. Selekcja w algorytmie NSGA [7]

#### Podsumowanie

W artykule zaprezentowano kilka wybranych metod ewolucyjnych w optymalizacji wielokryterialnej. Aktualnie do rozwiązywania skomplikowanych zagadnień optymalizacyjnych wykorzystuje się mechanizmy natury, które w wielu przypadkach pozwalają znaleźć dobre rozwiązania.

Nie we wszystkich koncepcjach algorytmów ewolucyjnych udało się uzyskać zadowalające rezultaty przy rozwiązywaniu zagadnień technicznych. Jednak wykorzystanie w/w metod optymalizacyjnych pozwala nam na wybranie z grupy rozwiązań dopuszczalnych najlepszego, biorąc pod uwagę przyjęte kryterium (na przykład: zysk, niezawodność).

W przypadku rozwiązywania zagadnień z wektorowymi wskaźnikami jakości należy tworzyć dodatkowe narzędzia, które będą realizować optymalizację wielokryterialną.

#### Literatura

- [1] Horn J., Nafpliotis N., Goldberg D.: A Niche Pareto Genetic Algorithm for Multiobjective Optimization, IEEE 1994.
- [2] Kulczycki J.: Optymalizacja struktur sieci elektroenergetycznych, WNT 1990.
- [3] Michalewicz Z.: Algorytmy genetyczne + struktury danych = programy ewolucyjne, WNT 1999.
- [4] <http://delta.cs.cinvestav.mx/~ccoello/EMOO/>
- [5] <http://www.mhahanas.de/MOEA/HDROMOGA/main.htm>
- [6] <http://155.158.112.34/~algorytmyewolucyjne/>
- [7] [http://staff.iiar.pwr.wroc.pl/ewa.sz...w\\_mo\\_metody\\_wielokryterialne\\_tel.pdf](http://staff.iiar.pwr.wroc.pl/ewa.sz...w_mo_metody_wielokryterialne_tel.pdf)
- [8] [http://155.158.112.34/~algorytmyewolucyjne/materialy/obliczenia\\_ewolucyjne.pdf](http://155.158.112.34/~algorytmyewolucyjne/materialy/obliczenia_ewolucyjne.pdf)
- [9] [www.wikipedia.pl](http://www.wikipedia.pl)

**Mgr inż. Michalina Gryniwicz-Jaworska**  
e-mail: [michalina.gryniwicz.jaworska@vp.pl](mailto:michalina.gryniwicz.jaworska@vp.pl)

Mgr inż. Michalina Gryniwicz-Jaworska jest doktorantem w Instytucie Informatyki Politechniki Lubelskiej. W swoich pracach zajmuje się zagadnieniami związanymi z optymalizacją wielokryterialną.



otrzymano/received: 2014.03.12

przyjęto do druku/accepted: 2014.10.15