

Zastosowanie grupowego algorytmu genetycznego w celu poszukiwania rozwiązania zagadnienia ekonomicznego rozdziału obciążeń pomiędzy bloki elektroenergetyczne

Streszczenie. Tematyka artykułu dotyczy zastosowania nowej wersji algorytmu genetycznego, określanej mianem grupowego algorytmu genetycznego, w celu rozwiązania zagadnienia ekonomicznego rozdziału obciążeń pomiędzy ciepłe bloki energetyczne występujące w systemie elektroenergetycznym. Główną zaletą grupowego algorytmu genetycznego jest fakt, że wartość funkcji dopasowania wyznaczana jest jednocześnie dla większej grupy osobników, co zapobiega przedwczesnej zbieżności tego rodzaju algorytmu do jednego z licznych optimum lokalnych.

Abstract. The topic of the paper is about implementation of a novel version of genetic algorithm, which is called a group-based genetic algorithm. We use this kind of algorithm in order to solve an economic dispatch problem among energetic blocks in the electrical energetic system. The main merit of the group-based genetic algorithm is that the fitness function is calculated simultaneously for a larger group of individuals which disables the premature convergence to some of the numerous local optima. (**Implementation of group-based genetic algorithms for economic dispatch problem in an electrical energetic system.**)

Słowa kluczowe: obliczenia ewolucyjne, grupowy algorytm genetyczny, system elektroenergetyczny, ekonomiczny rozdział obciążeń.

Keywords: evolutionary computation, group-based genetic algorithm, electrical energetic system, economic dispatch problem.

doi:10.12915/pe.2014.11.53

Wprowadzenie

W ostatnich latach dużą popularnością cieszą się różnorodne techniki obliczeniowe, których powstanie zostało zainspirowane odkryciami w zakresie nauk biologicznych [1]. Do tego typu metod zaliczane są między innymi algorytmy ewolucyjne, algorytmy genetyczne, strategie programowania genetycznego i ewolucyjnego, a także algorytmy rojowe i immunologiczne [2]. Głównymi obszarami zastosowań wymienionych typów algorytmów są przede wszystkim różnego rodzaju zagadnienia optymalizacyjne (w tym również optymalizacja wielokryterialna o dynamicznie zmieniających się uwarunkowaniach), a także klasyfikacja obiektów, estymacja, aproksymacja, interpolacja funkcji oraz predykcja szeregów czasowych [3]. Rozważane algorytmy inspirowane biologią są szczególnie chętnie stosowane przede wszystkim tam, gdzie zdają się zawodzić klasyczne metody obliczeniowe [4 – 7].

W artykule przeanalizowano możliwości zastosowania algorytmów genetycznych w celu poszukiwania rozwiązania zagadnienia ekonomicznego rozdziału obciążeń pomiędzy bloki energetyczne elektrowni ciepłych pracujących w systemie elektroenergetycznym [8]. Rozważane zagadnienie jest niezwykle ważnym problemem obliczeniowym spotykanym w obszarze elektroenergetyki, a jego istota sprowadza się do tego, w jaki sposób należy rozłożyć moc zapotrzebowaną przez odbiorców pomiędzy poszczególne bloki elektroenergetyczne pracujące w danym systemie elektroenergetycznym, aby całkowita masa spalonego w nich paliwa (węgla kamiennego bądź brunatnego) była możliwie jak najmniejsza [9].

Zagadnienie ekonomicznego rozdziału obciążeń posiada rozwiązania analityczne jedynie w przypadku, gdy nie są uwzględniane żadne dodatkowe ograniczenia nałożone na pracę systemu elektroenergetycznego. Niestety, pominięcie tego rodzaju ograniczeń, jak dopuszczalny zakres zmian poziomu mocy poszczególnych bloków energetycznych, czy też konieczność zbilansowania mocy w systemie elektroenergetycznym, prowadzi zwykle do odnalezienia rozwiązań, które nie posiadają żadnej użyteczności praktycznej [10]. W związku z powyższym w celu rozwiązania zagadnienia ekonomicznego rozdziału obciążeń w systemie elektroenergetycznym wydaje się być rzeczą uzasadnioną, aby podając próbę zastosowania

inspirowanych biologicznie technik obliczeniowych, takich jak na przykład algorytmy genetyczne.

Grupowe algorytmy genetyczne

Stosowane dotychczas z powodzeniem do rozwiązywania wielu różnorodnych zagadnień optymalizacyjnych algorytmy genetyczne częstokroć wykazują wybitnie „egoistyczne” zachowanie. Cała rzecz sprowadza się do faktu, że każdy z osobników tworzących ewoluującą populację ma na uwadze jedynie swój własny genotyp, który stara się za wszelką cenę udoskonalać w procesie ewolucji, natomiast pozostałe osobniki współwystępujące z nim w populacji traktuje jedynie jako swego rodzaju konkurencję, którą należy wszelkimi możliwymi sposobami zwalczać [11].

Taki „egoistyczny” sposób realizacji algorytmów genetycznych dobrze sprawdza się jedynie w przypadku rozwiązywania zagadnień optymalizacyjnych, które posiadają dokładnie jedno optimum globalne, wyróżniające się w istotny sposób na tle pozostałych występujących licznie w przestrzeni rozwiązań optimum lokalnych. Niestety wiele spotykanych w praktyce inżynierskiej problemów optymalizacyjnych nie da się zaliczyć do tego rodzaju kategorii, w związku z czym zastosowanie w ich przypadku algorytmu genetycznego w swej klasycznej postaci może okazać się nieskuteczne [4].

W pracy [12] zaproponowano interesujące rozwiązanie, polegające na takiej modyfikacji klasycznej wersji algorytmu genetycznego, aby tego rodzaju metody obliczeniowe mogły być także stosowane w przypadku zagadnień optymalizacyjnych, które posiadają więcej niż jedno dopuszczalne rozwiązanie.

Okazuje się, że tego rodzaju zagadnienia optymalizacyjne występują również w świecie biologii. Dobrym przykładem w tym względzie jest chociażby kolonia bakterii, która jest w stanie przetrwać, tylko dlatego, że wchodzące w jej skład poszczególne bakterie wyspecjalizowały się w zwalczaniu zagrożeń, za które odpowiedzialne są różnorodne czynniki chemiczne, takie jak na przykład różnego typu substancje wykazujące działanie antybiotykowe.

W rozpatrywanym przypadku, gdyby biologiczna ewolucja przebiegała w sposób podobny, jak ma to miejsce podczas realizacji klasycznej wersji algorytmów

genetycznych, wówczas cała kolonia bakterii zostałaby zdominowana przez podobne do siebie pod względem genetycznym osobniki, w związku z czym kolonia taka byłaby odporna na działanie tylko jednego rodzaju substancji antybiotykowej. Tymczasem w rzeczywistych koloniach bakteryjnych występują grupy osobników przystosowane do obrony przez różnymi rodzajami substancji antybiotykowych, co znacznie zwiększa szanse całej kolonii na przetrwanie w skrajnie niesprzyjających warunkach [12].

Analogiczne zjawisko można zaobserwować analizując sposób funkcjonowania systemów odpornościowych organizmów żywych. W rozpatrywanym przypadku każdy z organizmów żywych posiada zestaw wielu różnorodnych przeciwciał, dzięki czemu może skutecznie się bronić przed szkodliwym działaniem wielu różnorodnych antygenów [12].

Zamieszczone powyżej przykłady dowodzą, że wyznaczanie wartości funkcji dopasowania z osobna dla każdego z ewoluujących osobników jest zbyt daleko posuniętym uproszczeniem rzeczywistości, bowiem okazuje się, że aby móc przetrwać jako gatunek, poszczególne osobniki nie tylko w sposób bezwzględny konkurują ze sobą, ale równie często muszą także podjąć skuteczną współpracę w dążeniu do wspólnego celu.

W związku z powyższym w przypadku zastosowania grupowej wersji algorytmu genetycznego wartość funkcji dopasowania wyznaczana jest jednocześnie dla całej grupy osobników, co oznacza, że genotyp każdego z osobników na bezpośredni wpływ na jej ostateczną wartość. Z powyższego wynika, że aby funkcja dopasowania mogła osiągnąć odpowiednio wysoką wartość, wszystkie osobniki wchodzące w skład grupy, dla której wartość funkcji dopasowania jest wyznaczana, muszą w pewien sposób współpracować ze sobą, by w efekcie przyczynić się do wzrostu wartości funkcji dopasowania.

Implementacja zaproponowanej w pracy [12] grupowej wersji algorytmu genetycznego sprowadza się do tego, że cała populacja podlegających ewolucji osobników dzielona jest na dwie równoliczne grupy. Następnie wartość funkcji dopasowania wyznaczana jest z osobna dla każdej z dwóch grup. Grupa, w przypadku której funkcja dopasowania osiągnie większą wartość, nazywana jest grupą zwycięska i tylko ta grupa przechodzi do kolejnego pokolenia. Natomiast osobniki należące do pozostałej grupy zostają z populacji w sposób trwały wyeliminowane. Puste miejsce, powstałe po usunięciu z populacji osobników należących do grupy, która przegrała, zapelniane jest nowymi osobnikami utworzonymi poprzez przekopiowanie osobników należących do grupy zwycięskiej, przy czym każdy z takich osobników wprowadza do populacji dokładnie jedną swoją kopię (podlega klonowaniu).

Dodatkowo grupa osobników, które zostały przekopiowane, podlega genetycznej operacji mutacji, wykonywanej z określoną częstością (na przykład mutacji może podlegać statystycznie co setny bit materiału genetycznego osobników). Z kolei sama realizacja mutacji polega na losowym wyborze pozycji genowej i następnie na zanegowaniu wartości występującego na niej bitu, czyli w jej wyniku jedynka staje się zerem, a zero jedynką [1].

Ponadto wszystkie osobniki tworzące populację podlegają także genetycznej operacji wzajemnego krzyżowania ich materiałów genetycznych. W tym celu osobniki te łączone są losowo w pary, a następnie w ramach każdej z utworzonych w ten sposób par wybierany jest losowo punkt krzyżowania i leżące na prawo od niego fragmenty genomów obu osobników są zamieniane ze sobą miejscami, w wyniku czego powstają dwa całkowicie nowe osobniki potomne, które w różnym stopniu dziedziczą

materiały genetyczne pochodzące od każdego z ich osobników rodzicielskich [6].

W kroku kolejnym cała podlegająca ewolucji populacja osobników dzielona jest ponownie na dwie równoliczne grupy, przy czym wartość funkcji dopasowania wyznaczana jest oddzielnie dla każdej z dwóch grup, aby następnie można było spośród nich wyłonić grupę zwycięską.

Wymienione operacje powtarzane są w sposób iteracyjny aż do momentu, w którym spełniony zostaje warunek stopu. Realizację grupowego algorytmu genetycznego można przerwać na przykład po upływie określonej z góry liczby operacji lub zadanego z góry czasu, który może zostać przeznaczony na wykonywanie związanych z tym obliczeń. Jednak w praktyce korzystniej jest wprowadzić pewien rodzaj dynamicznego warunku zatrzymania procesu wykonywania obliczeń ewolucyjnych. Na przykład realizacja grupowego algorytmu genetycznego może zostać przerwana w sytuacji, gdy funkcja dopasowania dla jednej z grup osiągnie już odpowiednio wysoką wartość. Analogicznie realizację obliczeń ewolucyjnych można przerwać, gdy po upływie określonej z góry liczby iteracji nie udało się już zaobserwować dalszej poprawy odnalezionych dotychczas rozwiązań [5, 7].

Zagadnienie ekonomicznego rozdziału obciążeń

Jednym z podstawowych problemów optymalizacyjnych rozwiązywanych w ramach współczesnej elektroenergetyki jest zagadnienie ekonomicznego rozdziału obciążeń pomiędzy poszczególne bloki energetyczne elektrowni ciepłych pracujących w danym systemie elektroenergetycznym [8]. Zagadnienie ekonomicznego rozdziału obciążeń jest trudnym problemem optymalizacyjnym, w przypadku którego nie są znane żadne wzory analityczne, pozwalające na wyznaczenie optymalnych wartości mocy poszczególnych bloków energetycznych w przypadku, gdy uwzględnia się dodatkowo liczne ograniczenia, które w praktyce są nakładane na sposób ich pracy [10]. Jednocześnie należy wspomnieć, że nie uwzględnienie tego rodzaju ograniczeń prowadzi zwykle do uzyskania wyników, które pozbawione są jakiegokolwiek praktycznej użyteczności. Z tego powodu uzasadnione jest w przypadku poszukiwania rozwiązania zagadnienia ekonomicznego rozdziału obciążeń podejmowanie prób zastosowania wybranych heurystycznych algorytmów poszukiwań, w tym również algorytmów inspirowanych odkryciami w zakresie nauk biologicznych, takich jak na przykład algorytm genetyczny.

Jak już uprzednio wspomniano, zagadnienie ekonomicznego rozdziału obciążeń polega na takim wyznaczeniu mocy poszczególnych bloków energetycznych elektrowni ciepłych, aby całkowita masa spalonego w nich paliwa w jednostce czasu była możliwie jak najmniejsza przy jednoczesnym zachowaniu ograniczeń nałożonych na sposób pracy zarówno poszczególnych bloków energetycznych elektrowni ciepłych, jak i całego systemu elektroenergetycznego [8].

Podstawowa trudność z tym związana sprowadza się do tego, że masa paliwa spalonego w jednostce czasu w ciepłym bloku elektroenergetycznym Q jest funkcją nieliniową wartości mocy, z jaką pracuje dany blok. Na potrzeby prowadzonych obliczeń funkcję tę przybliża się funkcją wielomianową o następującej postaci:

$$(1) \quad Q = \alpha + \beta P + \gamma P^2 + \delta P^3 + \dots$$

W praktyce najczęściej uwzględnia się jedynie trzy pierwsze składniki funkcji wyrażonej wzorem (1), w związku z czym przyjmuje się, że masa paliwa spalonego w

jednostce czasu w cieplnym bloku elektroenergetycznym Q jest funkcją kwadratową mocy tego bloku.

Dodatkowo pamiętać należy o tym, że moc dowolnego bloku energetycznego elektrowni cieplnej bynajmniej nie może przyjmować dowolnych wartości, tylko musi być większa od zadanej wartości minimalnej P_{MIN} i jednocześnie mniejsza od zadanej wartości maksymalnej P_{MAX} . Wartości mocy P_{MIN} i P_{MAX} wynikają bezpośrednio z parametrów konstrukcyjnych danego bloku elektroenergetycznego [10].

Ponadto na pracę całego systemu elektroenergetycznego nałożony jest kolejny warunek związany z koniecznością zbilansowania w nim mocy. W tym wypadku chodzi o to, że suma mocy generowanych przez wszystkie znajdujące się w ruchu bloki elektroenergetyczne musi być równa łącznej mocy zapotrzebowanej przez odbiorców P_Z powiększonej o sumaryczną moc strat przesyłowych, powstających w elektroenergetycznych liniach wysokich napięć i transformatorach [9]. Konieczność zbilansowania mocy w systemie elektroenergetycznym prowadzi do następującego równania:

$$(2) \quad \sum_{i=1}^N P_i - \sum_{i=1}^N s_i P_i^2 = P_Z$$

Z postaci równania (2) wynika, że moc termicznych strat przesyłowych jest wprost proporcjonalna do kwadratu wartości przesyłanej mocy, a s_i jest odpowiednim współczynnikiem proporcjonalności. Ponadto przez N oznaczono liczbę aktualnie pracujących bloków elektroenergetycznych elektrowni cieplnych.

Jest rzeczą oczywistą, że w praktyce równanie zadane wzorem (2) nigdy nie może być spełnione w sposób dokładny, ponieważ sterowanie pracą systemu elektroenergetycznego sprowadza się zawsze do nieustannego balansowania wokół punktu równowagi mocy, w związku z czym łączna wartość mocy generowanej we wszystkich blokach elektroenergetycznych jest zawsze albo nieco zbyt wielka, albo zbyt mała w stosunku do mocy zapotrzebowanej P_Z powiększonej o sumaryczną moc strat przesyłowych, co znajduje swoje odzwierciedlenie w zmianach częstotliwości pracy systemu elektroenergetycznego i w zmianach poziomu mocy wymienianej z sąsiednimi systemami elektroenergetycznymi, z którymi istnieją bezpośrednie połączenia zrealizowane za pomocą linii przesyłowych prądu przemiennego bądź stałego [10]. Z tego powodu w praktyce wymaga się tylko, aby była spełniona następująca nierówność:

$$(3) \quad \left| \sum_{i=1}^N P_i - \sum_{i=1}^N s_i P_i^2 - P_Z \right| < \varepsilon$$

Występująca w nierówności (3) wielkość oznaczona jako ε jest maksymalną wartością dopuszczalnej odchyłki dotyczącej bilansu mocy w systemie elektroenergetycznym.

Zastosowanie grupowej wersji algorytmu genetycznego

Autorzy podjęli próbę zastosowania grupowej wersji algorytmu genetycznego na potrzeby poszukiwania rozwiązania zagadnienia ekonomicznego rozdziału obciążeń w systemie elektroenergetycznym. W przypadku gdy rozkład obciążeń przeprowadzany jest pomiędzy N znajdujących się w ruchu bloków energetycznych elektrowni cieplnych, tworzona jest populacja złożona z $2N$ osobników. Każdy z tych osobników koduje wartość mocy wyłącznie jednego bloku elektroenergetycznego. Ponieważ w praktyce

w obszarze elektroenergetyki wykorzystuje się jedynie 32 różne poziomy regulacji mocy bloków elektrowni cieplnych, dlatego do zakodowania mocy pojedynczego bloku wystarczy osobnik, którego materiał genetyczny składa się zaledwie z pięciu bitów, przy czym wartość mocy danego bloku wyznaczana jest za pomocą następującego wzoru:

$$(4) \quad P = P_{MIN} + (P_{MAX} - P_{MIN}) \frac{L}{31}$$

We wzorze (4) symbolem L oznaczono nieujemną liczbę binarną zapisaną na pięciu kolejnych bitach osobnika kodującego wartość mocy danego bloku elektroenergetycznego. Jak łatwo zauważyć, wartość liczby L mieści się w przedziale rozciągającym się od 0 do 31, w związku z czym postać wzoru (4) gwarantuje, że wartość mocy bloku nigdy nie wyjdzie poza dopuszczalny dla niej przedział rozciągający się od P_{MIN} do P_{MAX} .

Ponieważ podlegająca procesom ewolucyjnym populacja liczy $2N$ osobników, moc każdego z bloków elektroenergetycznych zakodowana jest dokładnie w przypadku dwóch różnych osobników, które wzajemnie stanowią konkurujące ze sobą w tym względzie rozwiązania.

Po wykonaniu genetycznej operacji mutacji osobników (w rozważanym przypadku zrezygnowano z realizacji operacji krzyżowania) cała populacja dzielona jest losowo na dwie równoliczne grupy, każda po N osobników, przy czym w każdej z tych grup muszą znaleźć się osobniki kodujące wartości mocy dla wszystkich bloków elektrowni cieplnych pracujących w systemie elektroenergetycznym. W związku z powyższym grupy te stanowią wzajemnie dla siebie konkurujące ze sobą rozwiązania, przy czym wartości funkcji dopasowania wyznaczane są oddzielnie dla każdej z dwóch grup osobników.

Grupa, w przypadku której funkcja dopasowania osiągnęła korzystniejszą wartość, traktowana jest jako grupa zwycięska i jej osobniki podlegają klonowaniu, w taki sposób, że każdy z nich wprowadza do populacji dokładnie jedną swoją kopię, przy czym osobniki należące do grupy, która przegrała, są usuwane z populacji. Dzięki takiemu rozwiązaniu liczebność populacji przez cały czas utrzymuje się na jednakowym poziomie i wynosi $2N$ osobników.

W kroku kolejnym osobniki, które stanowią klony osobników z grupy zwycięskiej, podlegają operacji mutacji, która wykonywana jest z określoną częstością. Jak już wcześniej wspomniano, podczas realizacji grupowego algorytmu genetycznego w celu poszukiwania rozwiązania zagadnienia ekonomicznego rozdziału obciążeń zrezygnowano z wykonywania genetycznej operacji krzyżowania osobników, ponieważ w tym wypadku prowadziłoby to do zbyt daleko posuniętej destrukcji odnalezionych do tej pory rozwiązań, co znacznie pogarszałoby zbieżność algorytmu, a w skrajnych przypadkach mogłoby wręcz uniemożliwić odnalezienie poszukiwanego rozwiązania [4].

Następnie cała populacja złożona z $2N$ osobników dzielona jest w sposób losowy na dwie równoliczne grupy (po N osobników każda) w taki sposób, że w każdej z tych grup znajduje się dokładnie po jednym osobniku kodującym wartość mocy dla każdego z aktualnie pracujących N bloków elektroenergetycznych. W etapie kolejnym dla każdej z dwóch wymienionych grup wyznaczana jest wartość funkcji dopasowania, przy czym na wartość tę mają bezpośredni wpływ genomy wszystkich osobników należących do danej grupy.

Z kolei samo wyznaczanie wartości funkcji dopasowania jest dość złożonym procesem i z tego względu należy poświęcić mu nieco więcej uwagi. Ogólnie rzecz ujmując,

dowolne z rozwiązań reprezentowanych przez N osobników tworzących jedną z grup może zostać zaliczone do dwóch wzajemnie rozłącznych kategorii, z których jedna obejmuje rozwiązania określane mianem dopuszczalnych, natomiast do drugiej zaliczane są rozwiązania, które nie są dopuszczalne. W przypadku rozwiązań określanych jako dopuszczalne spełniony jest zadany nierównością (3) warunek wynikający z konieczności zbilansowania wartości mocy w systemie elektroenergetycznym.

W związku z powyższym, jeżeli porównywane są ze sobą dwa rozwiązania reprezentowane przez materiały genetyczne osobników należących do odrębnych grup i oba rozpatrywane rozwiązania są rozwiązaniami dopuszczalnymi, wówczas należy porównać dla nich koszty paliwa spalonego w jednostce czasu we wszystkich blokach wchodzących w skład systemu elektroenergetycznego. W takim wypadku grupa osobników, dla której koszt paliwa spalonego w jednostce czasu we wszystkich blokach pracujących w systemie elektroenergetycznym jest mniejszy, uznawana jest za grupę zwycięską, a osobniki należące do pozostałej grupy zostają trwale wyeliminowane z ewoluującej populacji.

Z kolei, gdy rozwiązanie reprezentowane przez osobniki należące do pierwszej z dwóch rozważanych grup jest rozwiązaniem dopuszczalnym, natomiast rozwiązanie reprezentowane przez osobniki należące do drugiej grupy jest rozwiązaniem niedopuszczalnym, wówczas niejako w sposób naturalny za grupę zwycięską należy uznać grupę, której osobniki reprezentują swoimi genomami rozwiązanie dopuszczalne, ponieważ jakiegokolwiek rozwiązanie dopuszczalne jest w oczywisty sposób lepsze od dowolnego rozwiązania niedopuszczalnego.

W ostatnim z możliwych przypadków wzajemnemu porównaniu podlegają dwa różne rozwiązania niedopuszczalne. Co prawda, żadne z nich nie może zostać wykorzystane w praktyce, ponieważ nie jest wówczas spełniony warunek zbilansowania mocy w systemie elektroenergetycznym, jednak na potrzeby realizacji grupowego algorytmu genetycznego jedno z nich i tak musi zostać uznane za lepsze od pozostałego. W takim wypadku za lepsze rozwiązanie uznawane jest to, w przypadku którego warunek zbilansowania mocy w systemie elektroenergetycznym naruszony jest w mniejszym stopniu. W tym celu wprowadza się nową wielkość, określaną jako stopień zbilansowania mocy w systemie elektroenergetycznym, która zadana jest następującym wzorem:

$$(5) \quad B = \left| \sum_{i=1}^N P_i - \sum_{i=1}^N s_i P_i^2 - P_Z \right|$$

Z postaci wzoru (5) wynika, że wielkość B jest liczbą nieujemną, a w przypadku niespełnienia warunku zbilansowania mocy w systemie elektroenergetycznym jest ona liczbą dodatnią. W związku z powyższym w przypadku porównywania ze sobą dwóch rozwiązań, które nie są dopuszczalne, za lepsze należy uznać to, w przypadku którego wielkość B osiąga mniejszą wartość, gdyż w takim wypadku w stosunkowo mniejszym stopniu naruszony jest

bilans mocy w rozpatrywanym systemie elektroenergetycznym.

Zakończenie

W artykule przedstawiono propozycję adaptacji opisanego w pracy [12] grupowego algorytmu genetycznego na potrzeby poszukiwania rozwiązań zagadnienia ekonomicznego rozdziału obciążeń pomiędzy bloki elektrowni ciepłych pracujących w systemie elektroenergetycznym. Jak pokazują badania przeprowadzone przez autorów, algorytmy genetyczne w swej klasycznej postaci w przypadku ich zastosowania do poszukiwania rozwiązania zagadnienia ekonomicznego rozdziału obciążeń wykazują niekorzystną tendencję polegającą na tym, że stosunkowo szybko odnajdują rozwiązania, które są rozwiązaniami dopuszczalnymi, po czym proces poszukiwań grzęźnie na dobre w pewnym optimum lokalnym, uniemożliwiając tym samym dalszą poprawę jakości odnalezionych dotychczas rozwiązań.

Zastosowanie nowo zaproponowanej w literaturze przedmiotu grupowej wersji algorytmu genetycznego pozwala żywić pewne nadzieje, że właśnie ten sposób zapobiegania przedwczesnej zbieżności ewolucyjnego procesu poszukiwań, pozwoli w istotny sposób podnieść jakość rozwiązań odnajdywanych metodami opartymi na zastosowaniu algorytmów genetycznych.

LITERATURA

- [1] Goldberg D. E., Algorytmy genetyczne i ich zastosowania, Wydawnictwa Naukowo-Techniczne, Warszawa, 1996
- [2] Rutkowska D., Piliński M., Rutkowski L., Sieci neuronowe, algorytmy genetyczne i systemy rozmyte, Wydawnictwo Naukowe PWN, Warszawa-Łódź, 1997
- [3] Kucharski A., Prognozowanie szeregów czasowych metodami ewolucyjnymi, Wydawnictwo Uniwersytetu Łódzkiego, Łódź, 2013
- [4] Michalewicz Z., Algorytmy genetyczne + struktury danych = programy ewolucyjne, Wydawnictwa Naukowo-Techniczne, Warszawa, 2003
- [5] Flasiński M., Wstęp do sztucznej inteligencji, Wydawnictwo Naukowe PWN, Warszawa, 2012
- [6] Rutkowski L., Metody i techniki sztucznej inteligencji, Wydawnictwo Naukowe PWN, Warszawa, 2012
- [7] Arabas J., Wykłady z algorytmów ewolucyjnych, Wydawnictwa Naukowo-Techniczne, Warszawa, 2004
- [8] Kremens Z., Sobierajski M., Analiza systemów elektroenergetycznych, Wydawnictwa Naukowo-Techniczne, Warszawa, 1995
- [9] Kujaszczyk S., Brociek S., Flisowski Z., Gryko J., Nazarko J., Zdun Z., Elektroenergetyczne układy przesyłowe, Wydawnictwa Naukowo-Techniczne, Warszawa, 1997
- [10] Laudyn D., Pawlik M., Strzelczyk F., Elektrownie, Wydawnictwa Naukowo-Techniczne, Warszawa, 2000
- [11] Rieffel J., Knox D., Smith S., Trimmer B., Growing and evolving soft robots, *Artificial Life*, vol. 20, pp. 143-162, 2014
- [12] Tomko N., Harvey I., Virgo N., Philippides A., Many hands make light work: Further studies in group evolution, *Artificial Life*, vol. 20, pp. 133-181, 2014

Autorzy: dr inż. Zbigniew Handzel, Uniwersytet Jagielloński, Wydział Zarządzania i Komunikacji Społecznej, ul. Łojasiewicza 4, 30-348 Kraków, E-mail: zbigniew.handzel@uj.edu.pl, dr inż. Mirosław Gajer, AGH Akademia Górniczo-Hutnicza, Katedra Informatyki Stosowanej, al. Mickiewicza 30, 30-059 Kraków, E-mail: mirek.gajer@gmail.com