

38/2003

Raport Badawczy

RB/27/2003

Research Report

**Wpływ wybranych metod
selekcji na ewolucyjne
poszukiwanie optimum
w przypadku niestacjonarnych
zadań optymalizacyjnych**

J. Stańczak, K. Trojanowski

**Instytut Badań Systemowych
Polska Akademia Nauk**

**Systems Research Institute
Polish Academy of Sciences**



POLSKA AKADEMIA NAUK

Instytut Badań Systemowych

ul. Newelska 6

01-447 Warszawa

tel.: (+48) (22) 8373578

fax: (+48) (22) 8372772

Kierownik Pracowni zgłaszający pracę:
Prof. dr hab. inż. Zbigniew Nahorski

Warszawa 2003

Wpływ wybranych metod selekcji na ewolucyjne poszukiwanie optimum w przypadku niestacjonarnych zadań optymalizacyjnych

Jarosław Stańczak

Krzysztof Trojanowski

IBS PAN

IPI PAN

stanczak@ibspan.waw.pl

trojanow@ipipan.waw.pl

Algorytmy ewolucyjne (AE) są jednym z często używanych narzędzi we wszelkiego rodzaju zadaniach optymalizacyjnych. Ich szczególna przydatność uwidacznia się w przypadkach trudnych, gdzie inne metody nie dają zadawalających rezultatów. Optymalizacja zadań niestacjonarnych, o parametrach zmiennych w czasie jest jednym z takich przypadków. Jednakże, aby osiągnąć dobre rezultaty, przy użyciu AE, należy zastosować odpowiednie moduły budujące tę metodę. Jedną z kluczowych części AE jest zastosowana metoda selekcji osobników (rozwiązań) do populacji potomnej. Porównaniu jednej z najlepszych, standardowo używanych w AE metod – selekcji turniejowej oraz zaproponowanych przez nas metod analizujących skład populacji, poświęcona jest ta praca.

1. Wprowadzenie

Optymalizacja dynamiczna jest dość trudnym zadaniem obliczeniowym. Wymaga ona nie tylko znalezienia optimum (lub suboptimum) funkcji, ale jeszcze nadążania za nim w czasie, gdyż optymalizowana funkcja zmienia swój kształt, a co za tym idzie i połączenie optimum w przestrzeni.

Typowy algorytm ewolucyjny z kodowaniem rzeczywistoliczbowym i jedną z tradycyjnych metod selekcji może sobie poradzić z takim zadaniem, ale otrzymywane wyniki nie będą zbyt

dobrze. Wynika to z faktu, że standardowe wersje algorytmu są wykorzystywane głównie do optymalizacji statycznej i w takim też celu zostały wymyślone i zaprojektowane. Optymalizacja dynamiczna charakteryzuje się nieco inną specyfiką i dlatego też należy zaprojektować nieco odmienną wersję algorytmu ewolucyjnego do wykorzystania w tej dziedzinie. Różnice te wypuklają się głównie w przypadku selekcji. Otóż selekcja w optymalizacji dynamicznej powinna mieć bardzo starannie zrównoważone właściwości promowania najlepszych rozwiązań i pozostawiania w odwodzie pewnych osobników słabiej wyspecjalizowanych, lecz mogących być bardzo cennymi po zmianie parametrów zadania. Istnieją różne koncepcje rozwiązania tego problemu. Można je podzielić generalnie na dwa nurty:

- zwiększające elastyczność algorytmu;
- umożliwiającą pozyskiwanie i wykorzystywanie wiedzy o problemie.

Do pierwszej grupy należą m.in. metody oparte na wprowadzeniu do populacji dodatkowych osobników z „zewnątrz”, zwiększających różnorodność populacji [3] lub też rozbięciu populacji na kilka części i w ten sposób przechowaniu potrzebnych później genotypów[2].

W drugim przypadku najczęściej do algorytmu wprowadza się dodatkową pamięć, która przechowuje pewne zdobyte doświadczenia. Wprowadzenie pamięci może odbywać się na różnych poziomach:

- populacji, gdzie gromadzone są dodatkowe rozwiązania, osobniki lub ich fragmenty, mogące w przyszłości być podstawą do lepszych rozwiązań w zmienionych warunkach [1];
- osobnika, które przechowują więcej niż jedno rozwiązanie, jest to analogia do rzeczywistych organizmów żywych, które w znacznej mierze są diploidalne, a więc przechowują w jądrze informacje o 2 różnych zestawach genów [5];

- fragmentów genotypu osobnika, które można wykorzystać w dalszych etapach obliczeń ewolucyjnych [4].

Prezentowane w pracy rozwiązania – nowe metody selekcji, nawiązują raczej do pierwszej grupy przystosowań, choć zastosowany w symulacjach komputerowy algorytm ewolucyjny z rankingiem operatorów posiada elementy gromadzenia wiedzy o problemie, a więc należące do drugiej grupy przystosowań. Wydaje się, że przedstawione w tej pracy metody selekcji sterowanej i selekcji niszej mimo mają bardzo dobre właściwości, zbliżone do tych, jakie narzuca optymalizacja dynamiczna.

2. Optymalizacja dynamiczna

Jak to już zostało zaznaczone we wstępie do niniejszej pracy, optymalizacja obiektów (funkcji) niestacjonarnych, czyli takich, których parametry są zmienne w czasie, jest znacznie trudniejszym przypadkiem niż najczęściej spotykana optymalizacja statyczna. W optymalizacji statycznej należy znaleźć jak najlepsze rozwiązanie i jest na to dowolnie dużo (lub dość dużo) czasu. Ponadto większość wyuczonych lub zauważonych prawidłowości i informacji o optymalizowanym obiekcie nie zmienia się. W przypadku optymalizacji dynamicznej ramy czasowe są przeważnie ograniczone, gdyż optimum zmienia swoje położenie. Dodatkowo często żąda się, aby metoda obliczeniowa nadążała za zmieniającym się położeniem optimum. Niestety w przypadku dynamicznym informacje o optymalizowanym procesie, pozyskane w trakcie poszukiwania optimum mogą się bardzo szybko dezaktualizować i ich wykorzystanie może prowadzić do złych wyników.

W zagadnieniu optymalizacji obiektów niestacjonarnych można wyróżnić przypadki ze zmiennością cykliczną i ze zmiennością przypadkową. W pierwszym przypadku dobre wyniki rozwiązań można uzyskać stosując metody oparte na pamięci zdarzeń przeszłych, czyli nawiązujące w pewnym sensie do metod optymalizacji statycznej. W drugim przypadku

metody takie będą raczej zawodne i istotne jest zwiększenie elastyczności w poszukiwaniu nowych rozwiązań.

Te trudności w rozwiązywaniu zadań związanych z optymalizacją dynamiczną prowadzą do częstego stosowania w nich metod opartych na heurystykach, takich jak symulowane wyżarzanie, czy algorytmy ewolucyjne. Te ostatnie wydają się dysponować szczególnie silnym potencjałem do rozwiązywania takich zadań.

3. Zadanie testowe

Do symulacji komputerowych wykorzystane zostało środowisko zaproponowane przez Trojanowskiego i Michalewicza [9]. Definiuje ono wielowymiarową przestrzeń, podzieloną na wiele hipersześcianów z zawartymi w nich unimodalnymi i paraboloidalnymi funkcjami, wśród których poszukuje się maksimum globalnego. Funkcje z hipersześcianów różnią się wartościami zmiennych w czasie maksimów lokalnych. Zmiany zachodzą cyklicznie. W danej chwili istnieje tylko jedno optimum globalne, w jednym z hipersześcianów. Optima lokalne nie przesuwają się w przestrzeni, a jedynie zmieniają swoją wartość, przybierając większe lub mniejsze wartości. Dla przypadku trójwymiarowego otrzymujemy krajobraz przypominający szachownicę z „górką” o maksimum lokalnym wypadającym w środku każdego pola szachownicy. Wysokości wzniesień są różne i cyklicznie się zmieniają.

4. Algorytm ewolucyjny wykorzystany do rozwiązania zagadnienia

4.1 Zakodowanie rozwiązania i funkcja dopasowania osobnika

Rozwiązywane zadanie jest typowym przykładem optymalizacji funkcji ciągłej w R^n . Osobnik populacji jest więc wektorem liczb rzeczywistych o długości n . Dodatkowo zawiera pewne elementy, wymagane przez zmodyfikowany AE użyty do rozwiązania problemu. Tymi dodatkowymi elementami są:

- wektor liczb rzeczywistych o długości równej liczbie zastosowanych operatorów genetycznych, zawiera on współczynniki jakości operatorów, potrzebne do wyboru operatora (więcej szczegółów o tej metodzie znajduje się w punkcie 4.3);
- liczba całkowita – numer aktualnie wybranego operatora genetycznego do modyfikacji rozwiązania;
- flaga (true/false) – identyfikująca, czy dany osobnik był już modyfikowany w danej iteracji algorytmu.

Funkcja dopasowania oparta jest na opisanym wcześniej zadaniu optymalizacji dynamicznej i wprowadza przeskalowanie problemu do zakresu (0,1).

4.2 Operatory ewolucyjne zastosowane do rozwiązania problemu

Efektywność metod opartych na AE polega w dużej mierze na możliwości doboru operatorów ewolucyjnych, dopasowanych do specyfiki rozwiązywanego zadania. W opisywanym przypadku zastosowano następujące operatory:

- mutacja I – wstawienie na wybranej pozycji wektora rozwiązania wylosowanej liczby z zakresu możliwych do przyjęcia wartości w danym wymiarze;
- mutacja II – niewielka perturbacja wartości wektora rozwiązań na wylosowanej pozycji o wartość z przedziału (-5% - +5%);
- mutacja III – działa podobnie jak mutacja I, lecz obowiązkowo dla wszystkich współrzędnych wektora;
- mutacja IV – działa podobnie jak mutacja II, lecz obowiązkowo dla wszystkich współrzędnych wektora;
- krzyżowanie I – wymienia przecięte w wylosowanym miejscu fragmenty wektorów z rozwiązaniami dwóch osobników populacji;

- krzyżowanie II – na wylosowanych pozycjach wektora rozwiązań przeprowadza uśrednienie tych wartości, pochodzących od obu osobników.

4.3 Algorytm ewolucyjny z oceną operatorów

Obecność wielu operatorów genetycznych spowodowała konieczność ustalenia prawdopodobieństw ich występowania. W symulacjach zastosowano nową metodę doboru, bazującą na właściwościach operatora, opisaną w pracach [6], [7] i [8]. Im bardziej dany operator polepsza funkcję celu danego osobnika, tym większa staje się przypisana mu wartość współczynnika jakości, a co za tym idzie, większe jest prawdopodobieństwo jego występowania, co ilustruje wzór (4.1).

$$p_{ij}(t) = \frac{q_{ij}(t)}{\sum_{i=1}^{L(t)} q_{ij}(t)} \quad (4.1)$$

gdzie:

$q_{ij}(t)$ - współczynnik jakości i -tej operacji w chwili t dla j -tego osobnika populacji;

$p_{ij}(t)$ - prawdopodobieństwo wystąpienia i -tej operacji w chwili t dla j -tego osobnika;

$L(t)$ - liczba operacji genetycznych (może ona zależeć od czasu).

Każdy osobnik populacji posiada, oprócz zakodowanego rozwiązania, swój własny ranking operatorów, na podstawie którego losuje operator, który będzie go modyfikował w bieżącej iteracji. Metoda ta umożliwia adaptacyjne strojenie prawdopodobieństw występowania operatorów ewolucyjnych w zależności od potrzeb członków populacji rozwiązań i zgodnie z ich „upodobaniami”. Jest bardzo prawdopodobne, że w zależności od fazy działania optymalizacji ewolucyjnej, jak i położenia dancgo osobnika w przestrzeni rozwiązań lepiej działają różne operatory. Oczywiście operatory słabsze również mają pewne prawdopodobieństwo wystąpienia, gdyż zawsze utrzymywana jest dla nich pewna minimalna wartość współczynnika jakości, dzięki występowaniu we wzorze (4.2) składowej $q_{oij}(t)$

(pierwszy człon wzoru). Każdy operator, nawet nie przynoszący bezpośrednich korzyści, może jednak wprowadzać do populacji odpowiednie modyfikacje (tak, jak to ma miejsce z operatorem mutacji w tradycyjnym algorytmie genetycznym). Należy zaznaczyć, że na danego osobnika działa w jednej iteracji tylko jeden operator, można więc jego działaniu jednoznacznie przypisać zasługi modyfikacji osobnika:

$$q_{ij}(t+1) = \begin{cases} q_{0ij}(t) + \frac{x_{ij}(t+1)}{\bar{x}(t)} + \alpha_{ij}(t) \cdot q_{ij}(t) & \text{dla } i = l \\ q_{ij}(t) & \text{dla } i \neq l \end{cases} \quad (4.2)$$

gdzie:

$q_{ij}(t)$ - wartości współczynnika jakości operacji i osobnika j w iteracjach t ;

$q_{0ij}(t)$ - niewielka wartość stała (kredyt), uniemożliwiająca całkowite wyeliminowanie jakiegos operatora (może zależeć od czasu);

$x_{ij}(t+1)$ - poprawa funkcji celu, $x_{ij}(t+1) = Q(t) - Q(t+1)_{ij}$, ($Q(t)$ - najlepsze rozwiązanie znalezione dotychczas, $Q(t+1)_{ij}$ - wartość funkcji celu bieżącego osobnika) osiągnięte przez operację i dla osobnika j w iteracji t , w przypadku braku polepszenia równa zero;

$\bar{x}(t)$ - średnia wartość popraw funkcji celu uzyskana dotychczas;

$\alpha_{ij}(t)$ - współczynnik zapominania, uwydatniający rolę najświeższych danych, przy osłabianiu dawniejszych (może również zależeć od czasu);

l - indeks operatora wybranego w danej iteracji.

Drugi człon wzoru (4.2) - $x_{ij}(t)$ - stanowi poprawę funkcji celu rozwiązywanego zadania. W przypadku braku poprawy jest on równy zero.

Trzeci człon wzoru (4.2) przechowuje informację o dawniejszych osiągnięciach operatora, przemnożonych przez współczynnik zapominania $\alpha(t)$. Współczynnik zapominania jest odpowiedzialny za właściwe wyważenie wpływu nowszych i starszych osiągnięć na wartość współczynnika jakości operatora.

4. 4 Metody selekcji zastosowane do rozwiązania zadania

4.4.1 Selekcja metodą deterministycznej ruletki

Metoda deterministycznej ruletki, polega ona na przyjęciu takiej liczby potomków danego osobnika, jaka wynika z zaokrąglonego do najbliższej wartości całkowitej lub przez odrzucenie części ułamkowej stosunku wartości jego funkcji dopasowania do średniej wartości funkcji dopasowania dla całej populacji pomnożonego przez jej liczebność. Otrzymane wartości funkcji dopasowania są skalowane tak, aby zminimalizować błędy całkowitych przybliżeń rzeczywistych wartości funkcji dopasowania. Występujący mimo tego ewentualny niedomiar jest zapełniany najlepszymi osobnikami, które nie weszły do populacji lub też tymi o największych odrzuconych częściach ułamkowych. Nadmiar jest likwidowany przez eliminację odpowiedniej liczby najgorszych z wybranych osobników.

4.4.1 Selekcja histogramowa

Selekcja histogramowa tworzy listę osobników o różnych wartościach funkcji dopasowania. Lista ta jest przeważnie krótsza niż lista osobników w całej populacji z uwagi na często występujące powtórzenia tych samych osobników w populacji. Następnie obliczana jest średnia wartość funkcji dopasowania osobników z listy. Każdy osobnik z listy (tylko jeden o danej wartości funkcji dopasowania) przekazuje do populacji potomnej taką liczbę osobników, jaka wynika z zaokrąglonego do najbliższej wartości całkowitej stosunku wartości jego funkcji dopasowania do sumy wartości funkcji dopasowania dla listy, pomnożonego przez liczbę populacji potomnej. Zastosowano tu, podobnie jak w przypadku selekcji metodą deterministycznej ruletki, mechanizm skalowania wartości funkcji dopasowania, aby przeciwdziałać błędom zaokrągleń. Jeśli mimo tego powstanie populacja potomna o większej lub mniejszej od przewidywanej liczbie osobników, populacja jest uzupełniana najlepszymi osobnikami, które nie weszły już do nowego pokolenia (przy niedomiarze) lub też usuwane są najsłabsze z wybranych osobników (przy nadmiarze).

4.4.1 Selekcja mieszana

Wykorzystana do rozwiązania tego problemu metoda selekcji mieszanej składa się z dwóch metod składowych o znacząco różnych właściwościach: selekcji histogramowej (mającą właściwość znaczącego zwiększania zróżnicowania populacji) i deterministycznej ruletki (z silnym naciskiem na promowanie najlepszych osobników) [7]. Są one losowo wybierane i wykonywane w trakcie działania obliczeń ewolucyjnych. Prawdopodobieństwo wyboru i wykonania każdej z metod jest określane metodą pokazującą wzór (4. 3):

$$p_{his}(t+1) = \begin{cases} p_{his}(t) \cdot (1-a) & \text{dla } \max(F_{av}(t) - F_{min}(t), F_{max}(t) - F_{av}(t)) > 3 \cdot \sigma(F(t)) \\ p_{his}(t) \cdot (1-a) + 0.5 \cdot a & \text{dla } \left(\max(F_{av}(t) - F_{min}(t), F_{max}(t) - F_{av}(t)) \geq 0.5 \cdot \sigma(F(t)) \wedge \right. \\ \left. \max(F_{av}(t) - F_{min}(t), F_{max}(t) - F_{av}(t)) \leq 3 \cdot \sigma(F(t)) \right) \\ p_{his}(t) \cdot (1-a) + a & \text{dla } \max(F_{av}(t) - F_{min}(t), F_{max}(t) - F_{av}(t)) < 0.5 \cdot \sigma(F(t)) \end{cases}$$
$$p_{det}(t+1) = 1 - p_{his}(t+1)$$

(4.3)

gdzie:

$p_{his}(t)$ - prawdopodobieństwo wystąpienia selekcji histogramowej,

$p_{det}(t)$ - prawdopodobieństwo wystąpienia selekcji metodą deterministycznej ruletki;

$F_{av}(t)$, $F_{min}(t)$, $F_{max}(t)$ - średnia, minimalna i maksymalna wartość funkcji dopasowania w populacji;

$\sigma(F(t))$ - odchylenie standardowe wartości funkcji dopasowania w populacji.

Jeżeli populacja osobników posiada zbyt małe odchylenie standardowe ($\sigma(F(t))$) w stosunku do rozpiętości wartości funkcji dopasowania ($\max(F_{av}(t) - F_{min}(t), F_{max}(t) - F_{av}(t))$), wtedy następuje zwiększenie prawdopodobieństwa wystąpienia selekcji histogramowej (pozycja trzecia we wzorze (4.3)). W przeciwnym wypadku zwiększane jest prawdopodobieństwo wystąpienia selekcji metodą deterministycznej ruletki (pozycja pierwsza we wzorze (4.3)). Jeśli natomiast parametry populacji zawarte są w przedziale uznanym za korzystny, to prawdopodobieństwa wystąpienia obu metod selekcji są prawie równe (pozycja druga we

wzorce (4.3)). Należy zaznaczyć także fakt, że zawsze $p_{his}(t)+p_{det}(t)=1$, czyli któraś z metod zawsze musi wystąpić.

4.4.2 Selekcja niszowa

Selekcja niszowa opracowana została specjalnie do rozwiązywania zadań optymalizacji dynamicznej. Opiera się ona na podziale populacji na kilka podpopulacji. Kryterium podziału są wartości funkcji dopasowania osobników. Na wstępie podobnie jak w populacji histogramowej tworzona jest lista osobników o różnych wartościach funkcji dopasowania w populacji¹. Cały zakres występujących wartości tej funkcji jest dzielony na pewną liczbę przedziałów. Liczba ta jest jednym z parametrów metody, w symulacjach stosowano trzy podpopulacje o następujących parametrach:

1. 90%-100% najlepszych wartości funkcji dopasowania;
2. 50%-90% najlepszych wartości funkcji dopasowania;
3. 10%-50% najlepszych wartości funkcji dopasowania.

Każdy przedział ma zagwarantowany pewien procent osobników w populacji potomnej. Oczywiście im gorsze wartości funkcji dopasowania, tym mniejszy powinien być zagwarantowany procent potomków w populacji potomnej. Rozkład procentowy liczby potomków dla każdego przedziału również można dostosować do wymogów problemu, a w symulacjach zastosowano rozkład. Pierwszy przedział otrzymuje 60% miejsc w populacji potomnej, drugi przedział 30% miejsc i trzeci przedział 10% miejsc. Suma wszystkich pul z przedziałów daje całą populację potomną. Wybór osobników które przechodzą do populacji potomnej w ramach jednego przedziału może być dokonywany na różne sposoby. W

¹ W wielu przypadkach może się zdarzyć, że równym wartościom funkcji dopasowania odpowiadają różne osobniki. W zastosowanych wersjach selekcji histogramowej i mieszanej taki przypadek jest uwzględniany.

symulacjach komputerowych został zastosowany sposób wyboru najlepszych osobników w ramach przedziału.

4.4.3 Selekcja turniejowa

Metoda turnieju losowego polega na wybieraniu spośród wylosowanego zbioru osobników (mniejszego od całej populacji) jednego o najlepszej funkcji dopasowania. Osobniki do turnieju losowane są spośród całej populacji z jednakowym prawdopodobieństwem. Najczęściej stosowany jest wariant w którym losuje się dwa osobniki, a do populacji potomnej przechodzi najlepszy z wybranych, lecz w ogólnym przypadku rozmiar turnieju może być dowolny z zastrzeżeniem, że wybierany jest do populacji potomnej jeden, najlepszy osobnik. Losowanie przeprowadzane jest tyle razy, ile osobników ma liczyć populacja potomna. Jest to jedna z najpowszechniej stosowanych metod selekcji i uznawana za jedną z najlepszych w zastosowaniach praktycznych.

5. Wyniki symulacji komputerowych

Przeprowadzono symulacje komputerowe dla dwóch wersji zadań optymalizacyjnych z podziałem przeszukiwanego fragmentu przestrzeni trójwymiarowej na 16 (4x4) i 36 (6x6) sześcianów z funkcjami typu paraboloidalnego o nieznannej i zmiennej w czasie wartości optimum lokalnego. Do poszukiwania maksimum globalnego funkcji użyto AE z mechanizmem wyboru operatorów ewolucyjnych i operatorami opisanymi w punkcie 4.2. Przetestowano zachowanie trzech metod selekcji w przypadku optymalizacji dynamicznej: selekcji mieszanej, niszowej i turniejowej. Do porównania wyników zastosowano współczynnik jakości [10], zdefiniowany wzorem (5.1), będący miarą dostrojenia algorytmu do poszukiwanego optimum. Współczynnik ten ułatwia ocenę jakości metody rozwiązującej problem. W idealnym przypadku powinien wynosić 0, ale szczególnie dla chwil tuż po przełączeniu musi mieć on znacznie większą wartość, gdyż algorytm musi mieć trochę czasu na znalezienie nowego optimum.

$$A_d = \frac{1}{K} \sum_{i=1}^K (err_{i,\tau-1}) \quad (5.1)$$


gdzie:

τ - liczba iteracji, pomiędzy dwiema kolejnymi zmianami funkcji celu;

K - liczba zmian funkcji celu podczas symulacji;

$err_{i,\tau-1}$ - różnica między wartością najlepszego znalezionej rozwiązania, a wartością optymalną w ostatniej iteracji przed zmianą optymalizowanej funkcji.


We wszystkich symulacjach komputerowych wartość τ wynosiła 10, licznosc populacji rodzicielskiej 60 osobników, potomnej 360 osobników, z których wybierano kolejną populację rodzicielską.




Rys. 5.1. Wartość współczynnika A_d dla zadania 4x4: a - selekcja niszowa, b - selekcja mieszana, c - selekcja turniejowa.

Rys. 5.1 przedstawia zależność współczynnika jakości (5.1) dla trzech badanych metod selekcji w trakcie przebiegu 100 iteracji obliczeń ewolucyjnych. Widoczne jest na nim że selekcja turniejowa dostraja się do średnich wartości funkcji i nie potrafi w czasie 10 iteracji pomiędzy zmianami funkcji celu odszukać maksimum. Selekcja mieszana i niszowa mają dość podobne

osiągnięcia i bardzo szybko odnajdują wartość bardzo bliską optymalnej. Selekcja mieszana działa nieco szybciej, lecz znajduje nieco gorsze rozwiązania niż selekcja niszowa.



Rys. 5.2. Wartość współczynnika A_d w ostatniej iteracji przed zmianą funkcji celu dla zadania 4x4: a - selekcja niszowa, b - selekcja mieszana, c - selekcja turniejowa.



Rys. 5.3. Wartość współczynnika A_d w ostatniej iteracji przed zmianą funkcji celu dla zadania 6x6: a - selekcja niszowa, b - selekcja mieszana, c - selekcja turniejowa.

Rys. 5.2 i 5.3 przedstawiają wartość współczynnika A_d tuż przed zmianą „wyglądu” funkcji celu. Pokazują one stopień dostrojenia algorytmu do optimum po 10 iteracjach obliczeń. W obu przypadkach widoczne jest, że selekcja turniejowa nie sprawdza się w tego typu zadaniu, natomiast szczególnie w przypadku 6x6 widoczne są zalety selekcji niszowej, która o 2 rzędy wielkości wyprzedza selekcję mieszaną i o 4 rzędy wielkości selekcję turniejową.

Wydaje się, że przyczyną tego faktu jest to, że selekcja turniejowa zwraca uwagę jedynie na bieżące osiągnięcia osobników i tak też ukierunkowuje rozwój populacji. Pozostałe dwie metody selekcji starają się w jak największym stopniu zachować różnorodność populacji, nie tracąc przy tym nacisku na rozwój najlepszych rozwiązań. Tak więc gdy zmieni się postać funkcji celu, dochodzą do głosu osobniki słabsze na poprzednim etapie, stanowiąc dobry punkt wyjściowy do kolejnych obliczeń, a silny nacisk w kierunku aktualnego optimum powoduje szybkie zlokalizowanie obszaru atrakcji nowego optimum.

6. Wnioski

Celem pracy było sprawdzenie właściwości trzech metod selekcji osobników do kolejnej populacji w warunkach optymalizacji dynamicznej. Okazało się, że uważana tradycyjnie za jedną z najlepszych, metoda turniejowa nie sprawdza się w optymalizacji dynamicznej, natomiast zaproponowane metody selekcji mieszanej i niszowej mają bardzo dobre właściwości przy użyciu ich do rozwiązania tego typu problemów.

Literatura

- [1] Branke J.: *Memory Enhanced Evolutionary Algorithm for Changing Optimisation Problems*, CEC'99, IEEE Press, 1999.
- [2] Cedeno W., Vemuri V. R.: *On the Use of Niching for Dynamic Landscapes*, ICEC'97, IEEE Publishing, Inc., 1997.

- [3] Cobb H., Grefenstette J. J.: *Genetic Algorithms for Tracking Changing Environments*, V ICGA '93, Morgan Kaufman, 1993.
- [4] Goldberg D. E., Smith R. E.: *Nonstationary Function Optimisation Using Genetic Algorithms with Dominance and Diploidy*, II ICGA, Lawrence Erlbaum Associates, 1987.
- [5] Hadad B. S., Eick C. F.: *Supporting Polyploidy in Genetic Algorithms Using Dominance Vectors*, EP'97, vol 1213 LNCS, Springer, 1997.
- [6] Mulawka J. Stańczak J.: *Genetic Algorithms with Adaptive Probabilities of Operators Selection*, Proceedings of ICCIMA'99, New Delhi, India, 1999.
- [7] Stańczak J.: *Rozwój koncepcji i algorytmów dla samodoskonalących się systemów ewolucyjnych*, PhD, Politechnika Warszawska, 1999.
- [8] Stańczak J.: *Algorytm ewolucyjny z populacją "inteligentnych" osobników*, Materiały IV Krajowej Konferencji Algorytmy Ewolucyjne i Optymalizacja Globalna, Łądek Zdrój, 2000.
- [9] Trojanowski K., Michalewicz Z.: *Searching for Optima in Non-Stationary Environments*, Proc. Of the 1999 Congress on Evolutionary Computation – CEC'99, IEEE Publ., 1999.
- [10] Trojanowski K. Wierzchoń S. T.: *Studying Properties of Multipopulation Heuristic Approach to Non-Stationary Optimisation Tasks*, Proc. of IIPWM'03, 2003.

