

MODYFIKACJA WARIANTÓW SUKCESJI W EWOLUCYJNEJ METODZIE PLANOWANIA ŚCIEŻKI PRZEJŚCIA

Łukasz KUCZKOWSKI, Roman ŚMIERZCHAŁSKI

Politechnika Gdańska, Wydział Elektrotechniki i Automatyki, ul. G. Narutowicza 11/12, 80-233 Gdańsk, tel.: 58 348 63-11, e-mail: lkuczowski@ely.pg.gda.pl

Streszczenie: W pracy analizowano wpływ sukcesji na kształtowanie nacisku selektywnego w ewolucyjnej metodzie planowania ścieżek przejść. Opisano metody sukcesji oraz przedstawiono pojęcie nacisku selektywnego. Zrealizowano badania dla 4 rodzajów algorytmów ewolucyjnych, w każdym przypadku stosując inną metodę sukcesji. Przeprowadzono symulację, uwzględniając liczbę wymienianych osobników oraz różne metody zastępowania. Otrzymane rezultaty pozwalają na dobór metody sukcesji tak, aby zapewnić zbieżność oraz zachować zdolność algorytmu do przeszukiwania przestrzeni rozwiązań.

Słowa kluczowe: algorytmy ewolucyjne, planowanie ścieżki przejścia, sukcesja

1. WSTĘP

Jednym z zadań sterowania obiektem ruchomym (np. robotem mobilnym, autonomicznym pojazdem nawodnym) jest przeprowadzenie obiektu z punktu początkowego do zadanego punktu docelowego lub obszaru wykonywania zadania (misji). W tym celu należy wyznaczyć optymalną ścieżkę przejścia względem określonego kryterium, np. najkrótszego czasu dojazdu do punktu docelowego. Ścieżka ta musi omijać przeszkody, które traktowane są jako ograniczenia statyczne i dynamiczne. Zwykle ograniczenia dynamiczne interpretowane są jako inne obiekty ruchome, poruszające się po określonej trajektorii i z pewną prędkością. Przedstawiony problem sprowadzono do zadania optymalizacji z ograniczeniami statycznymi i dynamicznymi [1]. Problem został rozwiązany za pomocą metody ewolucyjnej [2]. Bazując na systemie wyznaczania ścieżek przejść Evolutionary Planner/Navigator (EP/N) [3] opracowano aplikację vEP/N++ [4,5], która uwzględnia specyfikę problemu unikania kolizji. Nowa wersja systemu uwzględnia specyfikę problemu unikania kolizji. Prezentowana wersja wykorzystuje różne typy obiektów statycznych oraz dynamicznych w celu modelowania bliskiego do rzeczywistego środowiska morskiego. Dalsze prace nad programem skupiły się na wprowadzeniu biblioteki algorytmów genetycznych GALib [6]. Zastosowanie biblioteki pozwala w prosty sposób zmieniać parametry algorytmu ewolucyjnego takie jak skalowanie funkcji przystosowania [7] oraz metody selekcji [8]. W oparciu o wbudowane mechanizmy biblioteki

przeprowadzono badania: mechanizmu niszczenia [9], wpływu nacisku selektywnego [10], wariantów operatorów genetycznych [11], wariantów algorytmów genetycznych [12] oraz opracowano koncepcję hierarchicznego algorytmu wyznaczania ścieżki przejścia [13].

Głównym celem pracy jest zbadanie wpływu sukcesji na nacisk selektywny w ewolucyjnej metodzie planowania ścieżki przejścia. Zastosowanie różnych wariantów sukcesji pozwala na kształtowanie nacisku selektywnego [8,14]. Umożliwia to zmianę proporcji pomiędzy fazami eksploracji a eksploatacji oraz kontrolę zdolności algorytmu do przeszukiwania przestrzeni rozwiązań. Artykuł zorganizowano następująco: w punkcie drugim przedstawiono system planowania ścieżek przejścia za pomocą metody ewolucyjnej, w trzecim metody sukcesji, w części czwartej przedstawiono przeprowadzone symulacje. W części końcowej podsumowano wyniki badań.

2. PLANOWANIE ŚCIEŻKI PRZEJŚCIA W UJĘCIU EWOLUCYJNYM

Problem planowania ścieżki przejścia definiuje się następująco: dla ruchomego obiektu o określonych własnościach dynamicznych i kinematycznych, poruszającego się w zdefiniowanym środowisku należy znaleźć ścieżkę przejścia między punktem początkowym a końcowym, która pozwala ominąć występujące w środowisku przeszkody statyczne i dynamiczne oraz spełnia kryteria optymalizacji. Problem można podzielić na dwa tryby odnajdywania ścieżki: off-line i on-line. W pierwszym trybie poszukiwanie ścieżki dokonuje się w środowisku stacjonarnym, gdzie uwzględnia się ruch innych obiektów dynamicznych. W trybie on-line planowanie ścieżki wiąże się z ciągłą zmiennością środowiska i nieprzewidywalnością ruchu obcych obiektów. W takim przypadku należy stale monitorować zmiany w środowisku i parametry ruchu obiektów. W wypadku jakiegokolwiek zmian, następuje ponowne wyznaczenie ścieżki w trybie off-line.

W celu rozwiązania problemu, podjęto badania nad systemem planowania ścieżek przejść z wykorzystaniem technik ewolucyjnych. Wykorzystując specyficzną wiedzę z dziedziny algorytmów ewolucyjnych opracowano system, który za pomocą specjalizowanej reprezentacji rozwiązań przez unikalną strukturę chromosomu i konstrukcji operatorów genetycznych modyfikujących chromosomy pozwala na poszukiwanie rozwiązań w ciągłej przestrzeni modelowanego środowiska.

Dokładny opis problemu oraz algorytmu rozwiązania został przedstawiony w referacie nr 29: Zastosowanie Wielopopulacyjnego Algorytmu Ewolucyjnego do Problemu Wyznaczania Ścieżki Przejścia [15].

3. SUKCESJA A NACISK SELEKTYWNY

4.1. Nacisk selektywny

Działanie algorytmu ewolucyjnego oparte jest na przetwarzaniu populacji osobników. Zgodnie z rysunkiem 2 przedstawiającym ogólny schemat działania algorytmu ewolucyjnego [16] wykonywane są kolejno etapy: reprodukcji, operacji genetycznych oraz sukcesji. Reprodukacja odpowiada za dobór osobników do populacji tymczasowej T^t . Premiowane są osobniki posiadające największą wartość funkcji przystosowania. Populacja tymczasowa powstała na bazie procesu reprodukcji podlega operacjom genetycznym. Utworzenie populacji potomnej O^t następuje poprzez dokonanie operacji genetycznych na populacji tymczasowej T^t . Etap sukcesji polega na tworzeniu nowej populacji bazowej P^{t+1} . W procesie tym wybierane są osobniki z populacji potomnej O^t oraz starej populacji bazowej P^t .

Właściwość algorytmu ewolucyjnego polegająca na poprawie średniej wartości przystosowania populacji bazowej za pomocą mechanizmu selekcji nazywamy naciskiem selektywnym. Zwiększenie nacisku selektywnego jest równoważne zwiększeniu liczby kopii osobnika najlepszego względem osobnika najgorszego w nowej populacji bazowej. Sukcesja określa sposób tworzenia nowej populacji bazowej. Na podstawie [16] wyróżniono poniższe metody sukcesji.

```

procedure Algorytm ewolucyjny
begin
   $t := 0$ 
  inicjacja  $P^0$ 
  ocena  $P^0$ 
while (not warunek stopu) do
  begin
     $T^t :=$  reprodukcja  $P^t$ 
     $O^t :=$  operacje genetyczne  $T^t$ 
    ocena  $O^t$ 
     $P^{t+1} :=$  sukcesja ( $P^t, O^t$ )
     $t := t + 1$ 
  end
end
  
```

Rys 2. Schemat ogólny algorytmu ewolucyjnego

4.2. Sukcesja z całkowitym zastępowaniem

Sukcesja z całkowitym zastępowaniem (rys. 3a) polega na usunięciu osobników ze starej populacji bazowej. Do nowej populacji bazowej przenoszone są wszystkie osobniki z populacji potomnej. Sukcesja ta nie wprowadza nacisku selektywnego. Przykładem takiego mechanizmu jest prosty algorytm genetyczny (SGA) [2,6].

4.3. Sukcesja z częściowym zastępowaniem

Proces tworzenia nowej populacji bazowej polega na częściowym zastąpieniu osobników ze starej populacji bazowej przez osobniki z populacji potomnej (rys. 3b). Liczba zastępowanych osobników określana jest przez użytkownika i zawiera się w przedziale od 0 – 100%.

Usuwanie osobników ze starej populacji bazowej może przebiegać według następujących schematów:

- usuwanie najgorzej przystosowanych osobników,
- usuwanie najlepiej przystosowanych osobników,
- usuwanie losowych osobników,
- usuwanie osobników rodzicielskich.


Przykładem wykorzystania sukcesji z częściowym zastępowaniem jest postępowy algorytm genetyczny (IGA) [6].

4.4. Sukcesja elitarna

Sukcesja elitarna (rys. 3b) jest szczególnym wariantem sukcesji z częściowym zastępowaniem. Z populacji potomnej wybiera się n najlepiej przystosowanych osobników (gdzie $n \in \langle 0, m \rangle$, m - wielkość populacji). Następnie wybrane osobniki dodaje się do nowej populacji bazowej, która podlega sortowaniu. W celu utrzymania stałej wielkości populacji bazowej usuwa się z niej n najgorszych osobników. Schemat ten zapewnia przetrwanie przynajmniej najlepszego osobnika. Przykładem zastosowania sukcesji elitarniej jest algorytm ewolucyjny z częściowym zastępowaniem (SSGA) [6].

4.5. Sukcesja elitarna w ujęciu wielopopulacyjnym

Sukcesja ta oparta jest o zasadę działania sukcesji elitarniej. Rolę populacji bazowej przyjmuje tu nadrzędna populacja elitarna (rys. 3c). Z każdej niezależnie ewoluowanej populacji wybierane jest n najlepszych osobników. Osobniki te wprowadzane są do populacji bazowej. W końcowym etapie usuwa się najgorsze osobniki tak, aby zachować stałą wielkość populacji. Przykładem działania takiej sukcesji jest algorytm wyspowy (podpopulacyjny, DGA) [6].



Rys 3. Schematy sukcesji w algorytmie ewolucyjnym

4. BADANIA SYMULACYJNE

Do badań wariantów sukcesji wykorzystano program vEPN++. Zaprojektowano w nim środowisko symulujące sytuację kolizyjną przedstawione na rysunku 4a. Obce obiekty posiadały następujące parametry:
 target 1 – prędkość 10 węzłów, kurs 90°,
 target 2 – prędkość 11 węzłów, kurs 270°.

Przeprowadzono symulację dla 4 różnych wariantów algorytmów ewolucyjnych opisanych w [6]:

- Simple GA (SGA) – sukcesja z całkowitą wymianą populacji (brak nacisku selektywnego),


- Incremental GA (IGA) – sukcesja z częściowym zastępowaniem populacji,
- Steady-State GA (SSGA) – sukcesja elitarna,
- Deme GA (DGA) – sukcesja elitarna w ujęciu wielopopulacyjnym.

Dla Incremental GA przeprowadzono symulacje z następującymi wariantami wymiany osobników: wymiana osobnika najlepszego, wymiana osobnika najgorszego, wymiana osobnika losowego, wymiana osobnika rodzicielskiego. Dla algorytmów SSGA i DGA przeprowadzono symulacje z zastępowaniem 6 oraz 15 osobników. Niezależnie od badanego zadania testowego przyjęto następujące parametry algorytmu ewolucyjnego:

- wielkość populacji – 30 osobników,
- liczba populacji (dla algorytmu DGA) - 3,
- prawdopodobieństwo krzyżowania – 0,8,
- prawdopodobieństwo mutacji – 0,15,
- selektor – ruletka proporcjonalna,
- liczba generacji – 400.


Do symulacji wybrano 10 losowych populacji początkowych. Następnie dla każdego wariantu algorytmu przeprowadzono symulacje z ich wykorzystaniem. Przykładowe rozwiązanie graficzne przedstawiono na rysunku 4b. Otrzymane wyniki uśredniono, a na ich podstawie wykonano wykresy przedstawiające zależność wartości funkcji przystosowania (F) od liczby generacji ($nGen$). Linia ciągłą oznaczono zmianę wartości najlepszego osobnika. Linia przerywaną oznaczono zmiany średniej wartości funkcji przystosowania w populacji. Ze względu na formę funkcji celu (1), (2), (3) oraz empirycznie dobrane wartości wagowe, jeżeli ścieżka przejścia narusza ograniczenia jej wartość przystosowania przekroczy 3000.

Na podstawie definicji przedstawionej w rozdziale 4, zwiększenie nacisku selektywnego jest równoznaczne ze zwiększeniem liczby kopii najlepszego osobnika w nowej populacji bazowej. Zgodnie z powyższym za miarę nacisku selektywnego przyjmujemy stosunek wartości funkcji przystosowania najlepszego osobnika do średniej wartości funkcji przystosowania w populacji.




Rys 4. a) Środowisko wykorzystane do badań, b) przykładowe rozwiązanie po 400 generacjach

Rysunek 5 przedstawia wykres dla algorytmu SGA. Całkowita wymiana populacji w procesie sukcesji skutkuje brakiem nacisku selektywnego. Krzywe przebiegu wartości średniej oraz najlepszej funkcji przystosowania nie są od siebie zależne.




Rys. 5. Wynik badań dla algorytmu SGA


Na rysunku 6 oraz rysunku 7 przedstawiono wykres dla algorytmu SSGA. W procesie sukcesji zastępowano dla rysunku 6 - 6 osobników, dla rysunku 7 - 15 osobników. W obu przypadkach silny nacisk selektywny prowadzi do zaniku różnorodności populacji po 10 generacjach.



Rys. 6. Wyniki badań dla algorytmu SSGA z zastępowaniem 6 osobników




Rys. 9. Wyniki badań dla algorytmu DGA z zastępowaniem 15 osobników




Rys. 7. Wyniki badań dla algorytmu SSGA z zastępowaniem 15 osobników

Rysunek 8 oraz rysunek 9 przedstawiają przebiegi dla nadrzędnej populacji algorytmu DGA. W procesie sukcesji zastępowano 6 oraz 15 osobników. Pokrywające się przebiegi wartości średniej oraz najlepszej świadczą o dużym nacisku selektywnym. Zastosowanie wielu populacji pozwala jednak na utrzymanie różnorodności rozwiązań. Skutkuje to utrzymaniem kompromisu pomiędzy eksploracją a eksploatacją.




Rys. 8. Wyniki badań dla algorytmu DGA z zastępowaniem 6 osobników

Kolejne wykresy przedstawiają rezultaty dla algorytmu IGA. Rysunek 10 dotyczy sukcesji elitarniej z losowo wymienianym osobnikiem. Wariant ten daje rezultat podobny do algorytmu SGA. Zauważono jednak mniejsze oscylacje wartości średniej funkcji przystosowania.




Rys. 10. Wyniki badań dla algorytmu IDA z wymianą losowego osobnika

Na rysunku 11 przedstawiono rezultat dla sukcesji elitarniej z wymianą najgorszego osobnika. Oscylacyjny przebieg wykresu średniej wartości funkcji przystosowania świadczy o utrzymywaniu różnorodności populacji. Mała amplituda zmian tej wartości świadczy o zbieżności populacji do jednego rozwiązania.




Rys. 11. Wyniki badań dla algorytmu IDA z wymianą najgorszego osobnika

Badania wymiany osobnika najlepszego (rys. 12) oraz rodzicielskiego (rys. 13) wykazały, że schematy te powodują rozbieżność algorytmu. Uzyskane za ich pomocą rozwiązania naruszały ograniczenia optymalizacji.



Rys. 12. Wyniki badań dla algorytmu IDA z wymianą najlepszego osobnika



Rys. 13. Wyniki badań dla algorytmu IDA z wymianą osobnika rodzicielskiego

Na podstawie analizy powyższych wykresów ustalono, że przy zastosowaniu algorytmu ewolucyjnego do rozwiązania problemu unikania kolizji na morzu najlepiej wykorzystać sukcesję elitarną lub jej wariant wielopopulacyjny. Warianty te zapewniają zbieżność oraz wprowadzają silny nacisk selektywny. Zastosowanie algorytmu wielopopulacyjnego powoduje dodatkowo zrównoważenie proporcji pomiędzy eksploracją a eksploatacją, niwelując w ten sposób negatywne skutki dużego nacisku selektywnego (szybkie wyczerpanie możliwości przeszukiwania szerokiego spektrum obszaru rozwiązań). Zastosowanie sukcesji z częściowym zastępowaniem osobników w wariacie usuwania osobnika najlepszego oraz rodzicielskiego prowadziło do rozbieżności algorytmu. Pozostałe rodzaje sukcesji dawały rezultaty gorsze niż w przypadku wykorzystania sukcesji elitarniej.

5. WNIOSKI

W artykule przedstawiono wpływ wariantów sukcesji na nacisk selektywny w ewolucyjnej metodzie wyznaczania ścieżki przejścia. Wykorzystując program vEPN++ zbadano 4 rodzaje algorytmów ewolucyjnych. Każdy algorytm stosował odmienną metodę sukcesji. W przeprowadzonych badaniach uwzględniono liczbę wymienianych osobników oraz warianty ich zastępowania. Na podstawie otrzymanych wyników sporządzono wykresy wartości średniej oraz najlepszej funkcji przystosowania w zależności od generacji. Pozwoliły one na określenie nacisku selektywnego dla każdego z badanych wariantów.

Przedstawione wyniki pozwalają na dobór metody sukcesji tak, aby zachować różnorodność populacji. Odpowiada ona za fazę eksploracji, która zwiększa prawdopodobieństwo znalezienia rozwiązania globalnie

optymalnego. Kontrola nacisku selektywnego pozwala na utrzymanie kompromisu pomiędzy fazą eksploracji a eksploatacją. Zapewnia to ciągle przeszukiwanie obszaru rozwiązań oraz ukierunkowanie algorytmu w stronę lepszego rozwiązania.

6. BIBLIOGRAFIA

1. Śmierczalski R.: Trajectory planning for ship in collision situations at sea by evolutionary computation, In Proc. of the IFAC MCMC'97, Brijuni, Croatia, 1997, s. 1-10, ISBN 0080429343
2. Goldberg D.E.: Genetic Algorithms in Search, Optimization, and Machine Learning, Boston: Addison-Wesley Longman Publishing Co., Inc., 1989, ISBN 0201157675
3. Xiao J., Michalewicz Z.: An Evolutionary Computation Approach to Robot Planning and Navigation, Rozdział w: Soft-Computing and Mechatronics, 1999, s. 117-141, ISBN 978-3-7908-1212-1
4. Śmierczalski R., Michalewicz Z.: Modeling of Ship Trajectory in Collision Situations by an Evolutionary Algorithm. IEEE Transaction on Evolutionary Computation, Vol.4, No.3, 2000, s. 227 – 241, ISSN 1089-778X
5. Śmierczalski R., Michalewicz Z.: Path Planning in Dynamic Environments, Rozdział w: Innovations in Robot Mobility and Control, 2005, s. 135-154, ISBN 978-3-540-26892-5
6. Wall M. GALib: A C++ Library of Genetic Algorithm Components. MIT, 1996.
7. Kolendo P., Śmierczalski R., Jaworski B.: Experimental research on evolutionary path planning algorithm with fitness function scaling for collision scenarios. In: Methods and algorithms in navigation Marine navigation and safety of sea transportation, Gdynia Maritime University, 2011, s. 85-91, ISSN 2083-6473
8. Kolendo P., Jaworski B., Śmierczalski R.: Comparison of Selection Schemes in Evolutionary Method of Path Planning, LNAI: Computational Collective Intelligence: Technologies and Applications Vol. 6923, Part II, 2011, s. 241-250, ISBN 978-3-642-23937-3
9. Śmierczalski R., Kolendo P., Kuczkowski Ł., Jaworski B., Witkowska A.: The niching mechanism in the evolutionary method of path planning, LNCS: Artificial Intelligence and Soft Computing, Vol. 7895, Part II, 2013, s. 101-112, ISBN 978-3-642-38609-1
10. Kuczkowski Ł., Śmierczalski R.: Selection Pressure in the Evolutionary Path Planning Problem, Advances in Intelligent Systems and Computing: Intelligent Systems in Technical and Medical Diagnostics, Vol. 230, 2014, s. 523-534, ISSN 2194-5357
11. Kuczkowski Ł., Kolendo P., Jaworski B., Śmierczalski R.: Mean Crossover in Evolutionary Path Planning Method for Maritime Collision Avoidance, Scientific Journals Maritime University of Szczecin, nr 30 (102), 2012, s. 70-77, ISSN 1733-8670
12. Śmierczalski R., Kuczkowski Ł., Kolendo P., Jaworski B.: Distributed Evolutionary Algorithm for Path Planning in Navigation Situation, TransNav - The International Journal on Marine Navigation and Safety of Sea Transportation, Vol. 7, nr 2, 2013, s. 293-300, ISSN 2083-6473
13. Jaworski B., Kuczkowski Ł., Śmierczalski R.: Extinction Event Concepts for the Evolutionary Algorithms, Przegląd

Elektrotechniczny, nr 10b, 2012, s. 252-255, ISSN 0033-2097

14. Back T.: Selective Pressure in Evolutionary Algorithms: A Characterization of Selection Mechanisms, Proceedings of the First IEEE Conference on Evolutionary Computation, 1994, s. 57-62, ISBN 0-7803-1899-4
15. Kuczkowski Ł., Śmierchalski R.: Zastosowanie Wielopopulacyjnego Algorytmu Ewolucyjnego do

Problemu Wyznaczania Ścieżki Przejścia, Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej Nr 36, 2013, ISSN 1425-5766

16. Arabas J.: Wykłady z algorytmów ewolucyjnych, Wydawnictwo Naukowo-Techniczne, Warszawa, 2001, ISBN 978-83-2042-970-1

MODIFICATION OF POST-SELECTION METHODS IN EVOLUTIONARY PATH PLANNING PROBLEM

Key-words: evolutionary algorithms, path planning, post-selection

In this paper an impact of post-selection methods on shaping selection pressure was analyzed. Different methods of post-selection has been described. The concept of selection pressure was presented. Research has been made for 4 kinds of evolutionary algorithm, in each case a different method of post-selection was used. The simulations was performed taking into account number of replaced individuals and various methods of replacement. Results allow to choose post-selection method, so that algorithm will be able to effectively search solution space and ensure its convergence.