

Hybrydowy algorytm mrówkowy wykorzystujący algorytm genetyczny do wyznaczania trasy w systemie nawigacji

A hybrid ant algorithm using genetic algorithm to determine the route in navigation system

Daniel Komar¹

Treść. Artykuł ma na celu zaprezentowanie nowej implementacji hybrydowego algorytmu mrówkowego, który do rozwiązywania postawionego problemu wyznaczenia optymalnej trasy przejazdu będzie wykorzystywał również algorytm genetyczny. Autor przedstawi wyniki symulacji przeprowadzonej na podstawie rzeczywistych danych, ukazując znaczny wzrost efektywności rozwiązywania problemu. Otrzymane wyniki wykazały, że nowy algorytm wyznaczał w większej liczbie przypadków znacznie krótszy czas przejazdu, a tym samym redukował występujące czynniki zakłócające i negatywnie wpływające na osobę kierującą pojazdem.

Słowa kluczowe: algorytm mrówkowy, algorytm genetyczny, system nawigacji

Abstract. The purpose of this paper is to present the new implementation of a hybrid ant algorithm that will also use a genetic algorithm in order to solve the problem consisting in optimal route calculation. The author will present results of simulations that were performed based on real data and showed a significant increase of problem solution effectiveness. The obtained results proved that the new algorithm determined in more number of cases a significantly shorter journey time and in consequence reduced the occurring confounding factors which had a negative impact on the person driving a vehicle.

Keywords: ant algorithm, genetic algorithm, navigation system

1. Wstęp

Algorytm mrówkowy i genetyczny jest stosunkowo nową techniką optymalizacji pozwalającą rozwiązać problem poszukiwania optymalnej trasy przejazdu. Nowoczesne implementacje tych algorytmów pozwalają rozwiązywać problem, określony w teorii złożoności obliczeniowej jako NP-trudny. Do tej klasy problemu możemy zaliczyć wyznaczanie trasy przejazdu pomiędzy dwoma punktami i problem chińskiego listonosza (*ang. Chinese postman problem*).

Podstawowym założeniem algorytmu mrówkowego jest naśladowanie zachowania kolonii mrówek występujących w realnym świecie. Natomiast ich odpowiednikiem w cyfrowej rzeczywistości są wygenerowane mrówki, które będą w ograniczonym zakresie dokonywały oceny alternatywnych wariantów w procesie decyzyjnym [2, 3]. Algorytm genetyczny z założenia naśladuje ewolucję osobników, występujących w przyrodzie. Podczas działania wykonuje podstawowe operacje krzyżowania i mutacji [4, 5]. Następnie na podstawie cyfrowego kodu genetycznego chromosomów, obliczana jest funkcja przystosowania każdego z osobników. Oba algorytmy bazują na podstawowych mechanizmach działania zachodzących w świecie przyrody, na podstawie których sformułowano ich główne zasady. Prekursorom poszukiwania nowych roz-

wiązań technicznych obserwacje świata natury dały wiele pomysłów mających we współczesnych czasach praktyczne zastosowanie w dziedzinie sztucznej inteligencji, jak również algorytmice. Twórcą algorytmu genetycznego jest John Henry Holland.

W artykule zostanie przedstawiony hybrydowy algorytm mrówkowy, który do wyznaczania optymalnej trasy przejazdu pomiędzy punktem początkowym i docelowym, będzie wykorzystywał algorytm genetyczny. Powstała nowa implementacja opisywanego rozwiązania będzie uwzględniała również wiele istotnych czynników zmieniających się w czasie rzeczywistym.

W dalszej części zostanie zaprezentowana symulacja działania nowego algorytmu przeprowadzona na rzeczywistych danych. Ma ona na celu sprawdzenie możliwości zwiększenia efektywności generowania optymalnego rozwiązania zadanego problemu.

2. Tło koncepcji

Weną twórczą do rozpoczęcia prac nad nową hybrydową implementacją algorytmu były prace psychologiczne Jądwigi Bąk prowadzone w Zakładzie Psychologii Transportu Drogowego Instytutu Transportu Samochodowego w Warszawie. Prowadzone badania dotyczyły wpływają-

cych na osobę kierującą pojazdem negatywnych czynników występujących w ruchu drogowym [1].

Głównym celem nowej implementacji jest dobieranie trasy przejazdu w taki sposób, aby zminimalizować liczbę negatywnych czynników występujących w otoczeniu podczas podróży. Z założenia miałyby to pozytywny wpływ na indywidualny stan emocjonalny kierowcy, poprawę bezpieczeństwa i zachowania wobec innych uczestników ruchu. Istotne w tym przedsięwzięciu jest ograniczenie liczby iteracji algorytmu, dostarczającego optymalne w danych warunkach rozwiązanie, gdyż czas potrzebny na wygenerowanie nowej trasy jest ściśle określony. Wynika to z faktu, że kierowca widzący nową informację musi mieć czas na podjęcie odpowiedniej decyzji i reakcji przed dojazdem do węzła komunikacyjnego.

3. Algorytm genetyczny

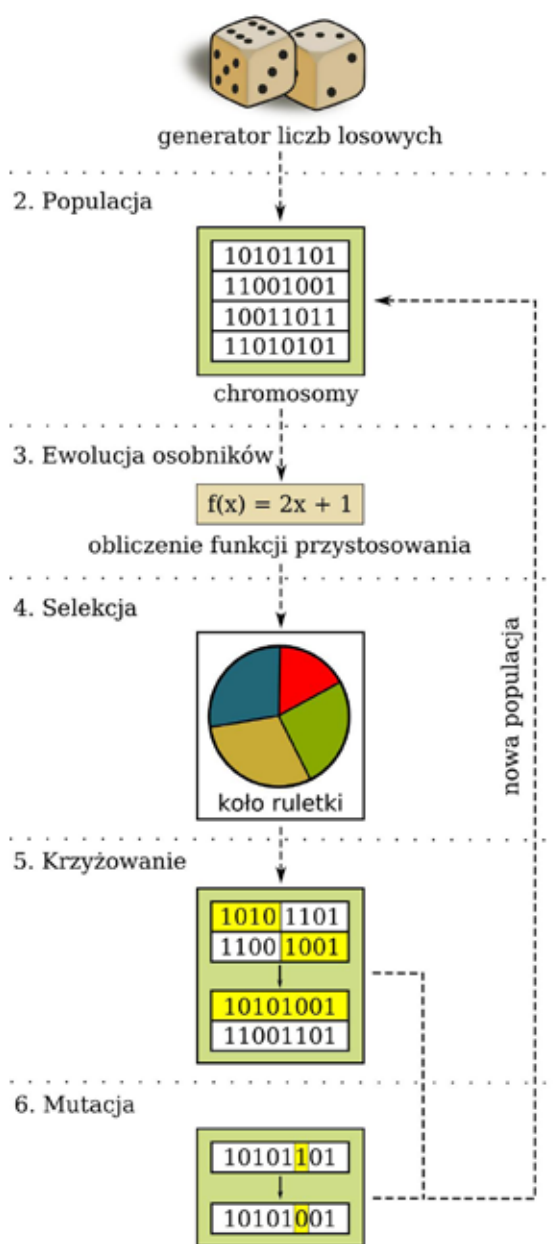
W prezentowanym rozwiązaniu istotne znaczenie odgrywa algorytm genetyczny, który został zaadaptowany do działania z algorytmem mrówkowym. Jest to algorytm ewolucyjny, będący stochastyczną metodą poszukiwania rozwiązania, bazującego na procesie naturalnej selekcji i ewolucji osobników zachodzącym w realnym środowisku [4, 5]. Każdy osobnik w populacji jest reprezentowany przez chromosom składający się ze zbioru symboli. Głównym założeniem algorytmu jest imitowanie czynności związanych z procesem manipulacji genami, do których można zaliczyć wykonywanie operacji krzyżowania i mutacji. Realizowanie elementarnych manipulacji na wygenerowanych chromosomach pozwoli tworzyć kolejne generacje osobników. Natomiast proces selekcji zostanie uzyskany poprzez odpowiedni dobór osobników do operacji krzyżowania.

W zaimplementowanym na potrzeby projektu algorytmie zbiór symboli składa się ze zbioru liczb naturalnych z zerem włącznie. Pierwszym i kluczowym etapem jest wygenerowanie początkowej populacji, który następuje tylko raz, podczas inicjacji działania algorytmu. Wygenerowane kolejno losowe wartości przez generator liczb losowych są wprowadzane do macierzy, reprezentującej chromosomy poszczególnych osobników tworząc populację. W kolejnej fazie jest obliczana wartość funkcji przystosowania. Wspomniana funkcja służy do znalezienia najlepszego rozwiązania oraz jej wynik wykorzystywany jest do wyznaczania indywidualnego prawdopodobieństwa krzyżowania poszczególnych par osobników. Wyższa wartość funkcji przystosowania danego osobnika zwiększa jego prawdopodobieństwo krzyżowania z innymi osobnikami w populacji. Następnie zostają określone procentowe przedziały dla każdego osobnika na tzw. kole ruletki i zostają wybrane pary osobników do krzyżowania przy pomocy generatora liczb losowych. Dzięki tej czynności imitowany jest proces naturalnej selekcji występujący w przyrodzie. W kolejnym kroku rozpoczyna się proces krzyżowania i mutacji. Proces krzyżowania dwóch osobników jest indywidualną rekombinacją ich cyfrowego kodu genetycznego,

który tworzy nowy chromosom osobnika kolejnej generacji. Proces mutacji może zachodzić podczas krzyżowania. Dzięki tej elementarnej operacji zostaje wprowadzona zmienność w kodzie chromosomów nowych osobników. W efekcie funkcja przystosowania osobników nie tylko w kolejnych generacjach ulega zwiększeniu, ale również może skutkować jej zmniejszeniem, co może prowadzić tym samym do znalezienia nowego lepszego niż poprzednio dostarczonego rozwiązania przez algorytm. Zmniejszeniem wykonania wszystkich opisanych operacji jest powstanie nowej populacji osobników.

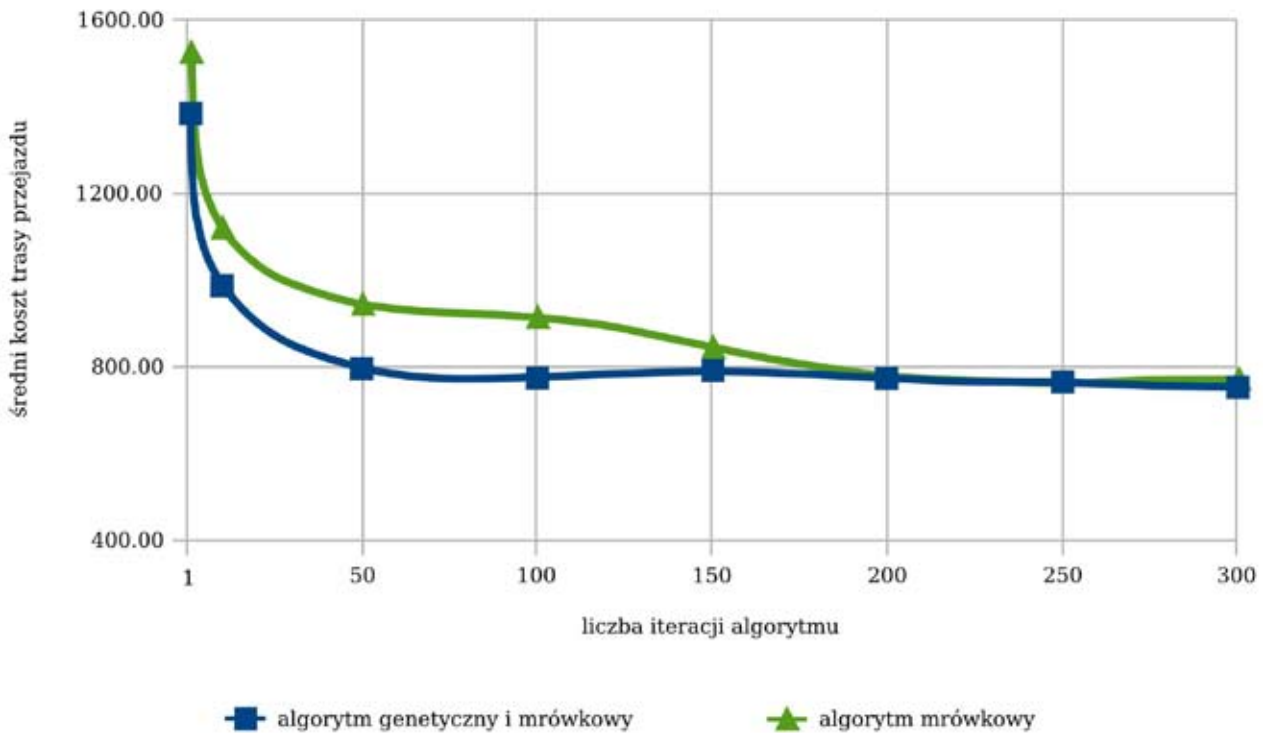
Opisane kroki wykonywanych czynności zostały zaprezentowane w uproszczeniu na schemacie (rys. 1.1). Z kolei ogólna struktura algorytmu genetycznego została zaprezentowana na listingu 1.1. Uproszczony pseudokod algorytmu genetycznego został napisany w języku programowania wysokiego poziomu Pidgin ALGOL.

1. Generowanie populacji



Rys. 1.1. Uproszczony schemat funkcjonowania algorytmu genetycznego

Fig. 1.1. A simplified scheme of the genetic algorithm working principle



Wyk. 1.1. Wykres prezentujący porównanie efektywność dwóch algorytmów
 Fig. 1.1. The chart showing comparison of the efficiency of two algorithms

węzły zostały zaznaczone na fragmencie miasta Wrocław. Zarówno nowy hybrydowy algorytm, jak i algorytm mrówkowy miał wygenerować trasę przejazdu przy ściśle określonej liczbie iteracji. Dla zadanej liczby iteracji wykonano kilkanaście prób i obliczono ich średnią wartość. Efektywność wyznaczania optymalnej trasy przez dany algorytm prezentuje wykres 1.1.

Połączenie metodologii dwóch różnych algorytmów względem poprzednio stosowanego rozwiązania, skutkuje znacznym zmniejszeniem liczby wymaganych iteracji do wyznaczenia optymalnego wyniku. Można również stwierdzić, że w większości przypadków hybrydowy algorytm generował trasę o znacznie niższym koszcie, a zwiększając liczbę iteracji jego wzrost efektywności [w pewnym okresie] utrzymywał się w przybliżeniu na stałym poziomie. Należy również mieć na uwadze, że otrzymane wyniki zależą od liczby osobników w populacji. W symulacji populacja liczyła dwudziestu ośmiu osobników i została ona uznana za najlepszą na podstawie wcześniej wykonanych testów.

Możemy również zobaczyć jak zmieniała się funkcja przystosowania w kolejnych generacjach osobników na wykresie 1.2. Z wykresu wynika, że dążyła tylko do maksymalizacji wartości najlepszego osobnika, ale również ulegała znacznym wahaniom wartości. Wspomniane oscylacje funkcji przystosowania są spowodowane występującymi mutacjami podczas krzyżowania chromosomów danych osobników.

Z obu wykresów możemy błędnie wywnioskować, że wahania wartości funkcji przystosowania mają znikomy wpływ na wyznaczony koszt trasy przez cyfrową mrówkę. Wbrew pozorom zmienność zachodząca w populacji poprzez efekt mutacji jest zamierzona i ma za zadanie


wyznaczyć jedne z droższych tras pomiędzy różnymi węzłami komunikacyjnymi. Następstwem tego jest nieutrzymywanie stałej osiągniętej wartości jako najlepszej, gdyż istnieje prawdopodobieństwo, że cyfrowa mrówka pomiędzy najdroższymi węzłami może się nie poruszać. Wyznaczenie o dużej wartości wag lokalnych połączeń pomiędzy dowolnymi węzłami zostaje osiągnięte poprzez operacje mutacji, co znacząco wpływa na proces decyzyjny i wynik generowany przez algorytm mrówkowy.

Na uwagę zasługuje fakt, że prezentowane w artykule wyniki zostały obliczone na podstawie wykonanych prób. Natomiast podczas wykonywania kolejnych symulacji wyniki mogą od siebie odbiegać. Wynika to z faktu, że są to algorytmy niedeterministyczne, a otrzymany wynik obliczeń jest indywidualny i może się każdorazowo różnić od poprzedniego. Symulację powtórzono kilkakrotnie i za każdym razem średnie wartości generowane przez algorytm, który wykorzystywał połączenie dwóch metod, uzyskiwał niższą wartość.

6. Podsumowanie

Zaprezentowane w artykule wyniki przeprowadzonych symulacji dowiodły, że połączenie możliwości obu algorytmów daje zaskakujące rezultaty. Powstała nowa implementacja pozwoliła na wyznaczenie optymalnej trasy przejazdu ze znacznie większą efektywnością przy stosunkowo małej liczbie iteracji. Wykorzystanie takich rozwiązań daje znaczne możliwości, ponieważ pozwala modyfikować na bieżąco trasę przejazdu pomiędzy węzłami w znacznie krótszym czasie.

Zastosowanie prezentowanego rozwiązania w systemie



Wyk. 1.2. Wykres prezentujący oscylację funkcji przystosowania w kolejnych generacjach osobników
 Fig. 1.2. The chart showing the oscillation of fitness function in the consecutive generations of new individuals

nawigacji pozwala bezpośrednio wpływać na stan emocjonalny i psychofizyczny kierowcy. Poprzez ograniczenie występujących w otoczeniu negatywnie wpływających czynników zakłócających zwiększa się bezpieczeństwo i komfort podróży. Ponadto w odbieranych bodźcach komunikacyjnych istotne stają się sygnały z otoczenia, które wymuszają na kierowcy podejmowanie istotnych decyzji. Zasadniczą rolę odgrywa proces antycypacji zdarzeń, umiejętnego wykorzystania schematów działania czy w wielu przypadkach myślenia abstrakcyjnego.

Możliwe, że podobne połączenia algorytmów w bliskiej przyszłości będą wykorzystywane w autonomicznych pojazdach do wyznaczania optymalnej trasy przejazdu, która może być modyfikowana w czasie rzeczywistym. Również tego typu algorytm pozwala na zwiększenie efektywności procesu decyzyjnego w określonym lokalnym środowisku, co może się przekładać na zachowanie takiego pojazdu na pewnym odcinku, wśród obecności innych uczestników ruchu. Musimy pamiętać, że możliwości takich algorytmów nie ograniczają się tylko do problemu wyznaczania trasy, a ich zastosowanie w dużej mierze zależy od wizji projektanta danego rozwiązania.

Literatura (References)

- [1] J. Bąk, *Psychologiczne badania kierowców*. Bezpieczeństwo pracy nr 6, pp.12-15, 2004.
- [2] M. Dorigo, L. M. Gambardella, *Ant Colony System: A Cooperative Learning Approach to the Traveling Salesman Problem*, IEEE Transactions on Evolutionary Computation, Vol.1, No.1, pp.53-66, 1997.
- [3] M. Dorigo, T. Stützle, *Ant Colony Optimization*, MIT Press, Cambridge 2004.
- [4] M. Mitchell, *An Introduction to Genetic Algorithms*, MIT Press, Cambridge 1999.
- [5] R. L. Haupt, S. E. Haupt, *Practical Genetic Algorithms*, 2nd Edition, John Wiley & Sons 2004.