

Aleksander KRÓL¹

POSZUKIWANIE ALTERNATYWNYCH STRUKTUR SIECI TRANSPORTOWYCH ZA POMOCĄ ALGORYTMU GENETYCZNEGO

Aktualna struktura sieci transportowych jest skutkiem długotrwałych i często przypadkowych procesów w przeszłości, jest więc niemal pewne, że nie jest ona optymalna dla obecnych potrzeb. Pilnym zadaniem jest zatem opracowanie metody umożliwiającej znalezienie optymalnej struktury sieci, odpowiadającej obecnym jak i prognozowanym potrzebom. Ze względu na brak analitycznego opisu i złożoność zagadnienia celowym wydaje się użycie metod sztucznej inteligencji. Jest bardzo prawdopodobne, że dla prawie każdego zestawu danych wejściowych istnieje kilka różnych rozwiązań o podobnej jakości, więc wiarygodna metoda powinna umożliwić jednoczesne znalezienie większości z nich. W pracy zaproponowano taką odmianę algorytmu genetycznego, która w sposób naturalny generuje alternatywne struktury sieci transportowej.

SEARCHING FOR ALTERNATIVE TRANSPORTATION NETWORK STRUCTURES USING A GENETIC ALGORITHM

The current network structure is usually the result of historical and often random long adaptation processes and it is almost sure not optimal for present demands. It is an urgent task to develop a method for searching the optimal transportation network structure, suitable for present and forecast demands. In the absence of analytical description and due to the complexity the usage of artificial intelligence methods seems to be the most appropriate. It is very likely, there are a few solutions of similar quality for almost each input data set. Therefore, the credible method should make possible a simultaneous obtainment most of them. In the paper the variant of genetic algorithm is presented, which in natural way generates alternative structures of a transportation network.

1. SIECI TRANSPORTOWE I ICH EWOLUCJA

Sieć transportowa to układ połączeń na danym obszarze ukształtowany pomiędzy skupiskami ludności w wyniku interakcji czynników ekonomicznych i społecznych oraz

¹ Politechnika Śląska, Wydział Transportu; ul. Krasińskiego 8, 40-019 Katowice
tel: +48 32 603 41 20, aleksander.krol@polsl.pl

środowiska naturalnego [8]. Obecna postać sieci transportowej jest wynikiem długotrwałego rozwoju, który rozpoczął się w początkach osadnictwa na danym obszarze.

Gdy na pewnym etapie rozwoju historycznego zachodziła potrzeba rozbudowy lub modernizacji sieci zawsze dążono do zaspokojenia chwilowych potrzeb bazując oczywiście na dotychczasowej strukturze sieci. Ponieważ bardzo często owe chwilowe potrzeby wynikały z różnych, nierzadko przypadkowych przyczyn (gospodarczych, politycznych, demograficznych, związanych ze zmianami środowiska naturalnego), które z biegiem czasu przestawały być aktualne obecna struktura sieci zazwyczaj nie jest optymalna.

Obecnie, gdy wymagana jest modernizacja lub rozbudowa sieci transportowej z reguły rozpatruje się kilka konkurencyjnych projektów i następnie wybiera jeden z nich. Taka procedura nie gwarantuje znalezienia rozwiązania optymalnego, gdyż tylko niewielki ułamek przestrzeni wszystkich możliwości jest poddany analizie.

Podjęciem alternatywnym jest opracowanie metody pozwalającej na znalezienie optymalnej struktury sieci transportowej na rozpatrywanym obszarze przy zadanych potrzebach komunikacyjnych i porównanie jej z istniejącą siecią. Pozwoliło by to na opracowanie wytycznych dla wymaganych modernizacji [7]. Prognozując różne warianty przyszłego rozwoju potrzeb transportowych można na drodze symulacji poszukiwać różnych rozwiązań i do realizacji wybrać to, które obiecuje długoterminowe zaspokojenie tych potrzeb przy akceptowalnych kosztach.

2. WYBÓR METODY OPTYMALIZACYJNEJ

Ze względu na to, że dane wejściowe dla tego problemu (charakteryzujące środowisko naturalne, rozkład skupisk ludności oraz intensywność komunikacji pomiędzy nimi) z reguły nie mogą być zadane w postaci analitycznej, naturalne jest zaproponowanie metod sztucznej inteligencji jako narzędzi optymalizacyjnych. Dzięki takiemu podejściu można znaleźć rozwiązanie zbliżone do optymalnego w stosunkowo krótkim czasie, eksplorując jedynie znikomy fragment przestrzeni rozwiązań. Bardzo obiecujące wydają się być procedury wykorzystujące algorytmy genetyczne [4].

3. ZASTOSOWANIE ALGORYTMU GENETYCZNEGO DO OPTYMALIZACJI STRUKTURY SIECI TRANSPORTOWEJ

Metody optymalizacyjne z użyciem algorytmów genetycznych naśladują proces ewolucji w świecie ożywionym i oparte są o następujące założenia [1]:

- konkurują ze sobą różne wersje rozwiązania (osobniki)
- struktura każdego osobnika zdeterminowana jest przez ciąg genów - genotyp
- genotyp podlega przypadkowym zmianom (mutacje)
- losowo wybrane pary osobników mogą wymienić między sobą fragmenty genotypów (krzyżowanie, crossover)
- funkcja dostosowania, będąca miarą dostosowania określa prawdopodobieństwo przejścia do następnego pokolenia (nacisk selekcyjny)
- połączenie przypadkowych mutacji i krzyżowania z ukierunkowanym naciskiem selekcyjnym prowadzi ku optymalnemu rozwiązaniu

Metoda optymalizacyjna oparta na algorytmie genetycznym pokonuje zasadniczy problem zagadnień optymalizacyjnych: dąży do maksimum globalnego, nie utykając w

otoczeniu jednego z maksimów lokalnych. Dzieje się tak, ponieważ do kolejnych etapów optymalizacji przechodzą również osobniki aktualnie gorzej dostosowane, a będące potencjalnymi kandydatami na rozwiązanie optymalne.

3.1. Model sieci transportowej w procesie optymalizacji

Sieć transportowa jest reprezentowana jako graf, którego gałęzie odpowiadają połączeniom, a wierzchołki skrzyżowaniom połączeń. W trakcie procesu optymalizacji modyfikowana jest zarówno topologia grafu – dodawane i usuwane są gałęzie i wierzchołki, jak i współrzędne wierzchołków oraz kształt połączeń. Założono dodatkowo, że połączenia mogą mieć przypisany dodatkowy atrybut – klasę, również podlegający optymalizacji. Niektóre z wierzchołków sieci są wyróżnione i nie podlegają modyfikacji – odpowiadają rzeczywistym miastom.

Funkcją celu minimalizowaną w procesie optymalizacji jest sumaryczny koszt budowy sieci transportowej i koszt jej użytkowania. Oba składniki są rozpatrywane w odpowiednio długim okresie, tak aby przy uwzględnieniu amortyzacji możliwe było ich porównanie.


Proces optymalizacji rozpoczyna się od utworzenia populacji początkowej zawierającej dowolne osobniki, następnie ich genotypy podlegają losowym mutacjom i krzyżują się między sobą. W kolejnym etapie wyliczane są funkcje dostosowania dla każdego osobnika. Następnie drogą losowania tworzone jest następne pokolenie, prawdopodobieństwo przejścia osobnika do następnego pokolenia jest zależne od wartości funkcji dostosowania. Po osiągnięciu zadanej liczby pokoleń lub osiągnięciu zadanej wartości funkcji dostosowania proces optymalizacji zostaje zatrzymany.

3.2. Genotyp kodujący sieć transportową, operatory mutacji i krzyżowania

Genotyp składa się z grafu reprezentującego sieć transportową oraz dodatkowo zawiera dla każdego połączenia ciąg liczb rzeczywistych kodujących jego kształt oraz liczbę całkowitą kodującą jego klasę.


Mutacje polegają na losowych zmianach genotypu. W związku z złożoną strukturą genotypu zastosowano kilka różnych operatorów mutacji:

- A. dodawanie i usuwanie połączeń
- B. jedno z istniejących połączeń zostaje związane z innym węzłem
- C. dodawanie i usuwanie węzłów sieci, przy czym "miasta" nie mogą zostać usunięte
- D. zmiana liczby punktów połączeń i ich współrzędnych odpowiada za zmianę kształtu połączenia
- E. zmiana klasy połączenia



Rys. 1. Przykładowe mutacje [6]

Również operatory krzyżowania nie mogą działać całkowicie przypadkowo i wymieniać dowolnych części genotypu, gdyż prowadziłyby do powstania nieprawidłowych genotypów nie kodujących żadnych sieci. Problem ten został rozwiązany przez wprowadzenie procedur wyszukujących w grafie autonomicznych fragmentów rozpiętych pomiędzy takimi samymi podzbiorami miast. Jeśli uda się znaleźć zbiór analogicznych takich fragmentów dla dwóch osobników kandydujących do krzyżowania, to podlegają one losowej wymianie.



Rys. 2. Krzyżowanie się osobników [6]

Tak zdefiniowany operator krzyżowania zgodnie z hipotezą o cegiełkach umożliwia wydajne generowanie lepiej przystosowanych potomków z osobników o mniejszej wartości funkcji celu, a których struktura zawiera wysokiej jakości fragmenty.

3.3. Wyznaczanie funkcji dostosowania

Jako wartość funkcji dostosowania osobnika przyjęto odwrotność sumarycznych kosztów budowy i użytkowania sieci.

$$f_f = \frac{1}{(K_B + K_U)^q} \quad (1)$$

gdzie: K_B – koszt budowy,
 K_U – koszt użytkowania.
 q – wykładnik modyfikujący, domyślnie $q = 2$

Zmienne koszty budowy, zależne od szczegółów środowiska naturalnego lub zastanej infrastruktury mogą być przedstawione w postaci mapy – "poła kosztów". Dogodnym sposobem wprowadzenia tych danych jest użycie mapy bitowej w odcieniach szarości. Wartości pikseli wzdłuż połączenia reprezentują lokalny modyfikator kosztu budowy: biały piksel odpowiada kosztom zerowym, czarny odpowiada kosztowi maksymalnemu. Klasa połączenia jest uwzględniona poprzez właściwy współczynnik ($k_b[cl]$). Koszt budowy pojedynczego połączenia może być więc wyrażony jako:

$$K_{Bi} = D_i k_b[cl] \sum_1^n \frac{1}{n} (0xFF - g_i)^p \quad (2)$$

gdzie: D_i – długość połączenia,
 n – liczba pikseli wzdłuż połączenia.
 p – wykładnik modyfikujący rozkład, domyślnie $p = 1$

Dużo trudniejszym zagadnieniem jest wyliczenie kosztów użytkowania sieci przez wszystkie pojazdy na podstawie macierzy intensywności ruchu. Dla każdego pojazdu można wyróżnić dwa składniki tych kosztów:

- koszt "fizyczny", do którego największy wkład wnosi wartość zużytego paliwa i ewentualne opłaty drogowe; ponadto należy uwzględnić amotyzację pojazdu oraz koszty związane z jego utrzymaniem.
- koszt "społeczny", będący pieniężnym ekwiwalentem czasu straconego na podróż.

Koszt użytkowania połączenia przez jeden pojazd zależy również od aktualnego obciążenia. Zależność ta może być modelowana w różny sposób, tutaj przyjęto, że koszt ten jest proporcjonalny do czasu zużytego na pokonanie danego odcinka. Do obliczenia czasu podróży zastosowano formułę wprowadzoną przez US Bureau of Public Roads [10]:

$$K_{U_i} = D_i k_u[cl] \left(1 + \alpha \left(\frac{O_i}{g[cl]} \right)^\beta \right) \quad (3)$$

gdzie: D_i – długość połączenia,
 $k_u[cl]$ – koszt jednostkowy w ruchu swobodnym w zależności od klasy,
 O_i – obciążenie połączenia
 $g[cl]$ – obciążenie graniczne (przepustowość) w zależności od klasy
 α, β – parametry kalibracyjne

Dla prostoty, na obecnym etapie rozwoju opisywanego modelu nie wprowadzono rozróżnienia pojazdów według typów. Uśredniona wartość kosztu jednostkowego w ruchu swobodnym została oszacowana dla każdej klasy połączenia i zawiera oba wymienione wcześniej składniki.

Wyznaczenie rozkładu strumieni ruchu pomiędzy drogi alternatywne jest w ogólności złożonym podzadaniem optymalizacyjnym [4, 5, 7]. Przyjęto, że strumienie ruchu są rozdzielane w sieci transportowej przy przyjęciu systemu opisowego: każdy kierujący wybiera drogę tak, aby ponoszone przez niego koszty były jak najmniejsze. Dla przyspieszenia obliczeń zamiast szukać drogi dla każdego kierującego zastosowano przybliżoną procedurę, dzieląc całkowite natężenie ruchu tylko na kilkadziesiąt części. W każdym kroku, poczynając od wartości zerowej natężenie jest zwiększane o taki sam ułamek i wtedy szuka się dróg aktualnie najtańszych przy użyciu algorytmu Dijkstry. Znalezione drogi są następnie obciążane bieżącym ułamkiem natężenia ruchu.

3.4. Jednoznaczność rozwiązania

Algorytm genetyczny jest procedurą niedeterministyczną, więc rozwiązania uzyskiwane w kolejnych przebiegach różnią się od siebie. Różnice te są dwojakiego typu:

- niewielkie rozbieżności, najczęściej w szczegółach przebiegu połączeń, rzadziej w klasie połączeń lub topologii sieci.
- całkowicie odmienna struktura sieci, ale z reguły bardzo zbliżona wartość funkcji celu.

W pierwszej sytuacji wystarczy niewielka korekta otrzymanego rozwiązania w celu osiągnięcia prawdziwego optimum. Występowanie drugiego przypadku sygnalizuje, że zagadnienie ma więcej niż jedno rozwiązanie. Potencjalne rozwiązania problemu mogą mieć identyczne, choć najczęściej mają tylko zbliżone wartości funkcji celu. Ponieważ budowa modelu sieci transportowej wymaga wprowadzenia różnych uproszczeń niewielkie różnice w wartości funkcji celu nie mają znaczenia i wszystkie takie rozwiązania powinny być traktowane jako równoważne.

3.5. Wyspowy algorytm genetyczny

Klasyczny algorytm genetyczny tymczasem zmierza zawsze w kierunku tylko jednego z rozwiązań, a inne warianty są z populacji wypierane. Takie zachowanie się jest pośrednią konsekwencją twierdzenia o schematach [1]. Jeśli problem ma więcej niż jedno rozwiązanie, to w trakcie niedeterministycznego procesu ewolucji prawdopodobieństwo

równoczesnego odkrycia dobrze rokujących kandydatów jest bardzo małe, zatem protoplasta jednego z rozwiązań pojawi się raczej wcześniej niż pozostali. Osobniki wywodzące się od niego będą stopniowo dominować populację, uniemożliwiając ewolucję rozwiązań alternatywnych. Nie stoi to w sprzeczności z podkreśloną wyżej zaletą algorytmów genetycznych polegającą na omijaniu maksimów lokalnych. Dzieje się tak, ponieważ w przypadku, gdy jako pierwszy zostanie odkryty dobrze rokujący osobnik odpowiadający tylko maksimum lokalnemu, to zanim jego potomkowie wyprą inne warianty jest prawie pewne, że gdzieś w populacji wyniku mutacji i krzyżowania się pojawi się kandydat na maksimum globalne o dużo wyższej wartości funkcji dostosowania. I to jego potomkowie zaczną od tej chwili dominować populację. Bardzo rzadko zdarza się więc, że procedura optymalizacyjna ugrzęźnie daleko od optimum globalnego i dobre rozwiązanie nie jest otrzymywane w ogóle.

Natomiast w przypadku występowania wielu maksimów o podobnych wartościach funkcji dostosowania, prawdopodobieństwo powstania nowego osobnika o znacząco wyższej wartości tej funkcji i utrzymania się jego potomków w epoce dominacji wcześniej znalezionej kandydata na optimum jest znacząco mniejsze.

Uzyskanie zbioru obejmującego wszystkie, albo przynajmniej większość z akceptowalnych rozwiązań wymagałoby więc wielokrotnego uruchomienia procedur optymalizacyjnych i oczekiwania na pojawienie się różnych wariantów rozwiązania. Takie postępowanie, oprócz uciążliwości ma jeszcze poważniejszą wadę: istnieje możliwość, że potencjalnie najlepsze rozwiązanie zostanie przeoczone. Ponadto, z psychologicznego punktu widzenia uzyskiwanie z pozoru przypadkowych rezultatów przy takich samych danych wejściowych sugeruje małą wiarygodność metody.

Pojawia się zatem potrzeba takiej modyfikacji algorytmu genetycznego, aby było możliwe jednoczesne poszukiwanie różnych wariantów rozwiązania. Najprostsze podejście polega na zastosowaniu modelu wyspowego: populacja zostaje podzielona na ustalone podpopulacje, które ewoluują w zasadzie oddzielnie [3]. Co jakiś czas jednak pomiędzy nimi następuje wymiana informacji – dopuszczone jest krzyżowanie się osobników pochodzących z różnych podpopulacji. Dzięki tym zmianom dwie najpoważniejsze wady klasycznego algorytmu genetycznego zostają usunięte:

- prawdopodobieństwo ugrzęźnięcia daleko od optimum globalnego jest bardzo małe (musiałoby się to zdarzyć jednocześnie we wszystkich podpopulacjach)
- jeśli istnieje więcej niż jedno rozwiązanie optymalne, to najlepsze z nich zostaną znalezione w jednym przebiegu procedur optymalizacyjnych.

Model wyspowy nie jest prostym zrównolegleniem kolejnych przebiegów algorytmu klasycznego. Dzięki wymianie informacji pomiędzy podpopulacjami najlepsze rozwiązania cząstkowe mają szansę na rozprzestrzenienie się w całej populacji, jednocześnie niewielkie prawdopodobieństwo tej wymiany gwarantuje dość dużą niezależność ewolucji i zmierzanie do różnych rozwiązań. W opracowaniach teoretycznych poświęconych wyspowym algorytmom genetycznym wiele uwagi poświęca się schematowi wymiany pomiędzy podpopulacjami, rozważając różne topologie przepływu informacji oraz częstość tego przepływu [2, 9]. W prezentowanej pracy założono prosty, całkowicie losowy schemat wymiany: w każdym pokoleniu, dla każdego osobnika z dowolnej podpopulacji istnieje bardzo niewielkie prawdopodobieństwo doboru partnera z innej, losowo wybranej podpopulacji. Takie rozwiązanie mimo, że jest najprostsze, prawdopodobnie najlepiej

przybliża zjawiska zachodzące w świecie ożywionym. Jednocześnie nie wydaje się być dużo mniej wydajnym schematem niż wspomniane wyrafinowane rozwiązania.


Algorytm genetyczny w wersji wyspowej pomimo przedstawionych wyżej zalet ma kilka ograniczeń:

- podział na grupy – podpopulacje jest z góry ustalony, zatem wymagana jest przynajmniej orientacyjna znajomość liczby spodziewanych różnych rozwiązań. Liczba podpopulacji powinna być co najmniej jej równa. Przy równoległej ewolucji może zdarzyć się tak, że w dwóch lub więcej podpopulacjach znalezione zostanie praktycznie to samo rozwiązanie, a tymczasem jakieś inne, zasadniczo różne pozostanie nie odkryte.
- prawidłowa ewolucja w niezależnych podpopulacjach wymaga pewnej minimalnej liczebności tych podpopulacji.

Obie wymienione właściwości modelu wyspowego w efekcie nakładają wymóg, aby liczebność populacji była większa niż w algorytmie klasycznym, co zwiększa w widocznym stopniu czas obliczeń. Zwiększony czasu obliczeń jest jednak i tak nieporównywalnie mniejszy od sumarycznego czasu wymaganego dla wielokrotnych przebiegów algorytmu klasycznego.


4. WYNIKI

Przedstawiony model sieci transportowej nie jest jeszcze na tyle zaawansowany, aby zastosować go do realnego obszaru i z realnymi danymi dotyczącymi natężenia ruchu. W szczególności należy dopracować metody pozyskiwania i opracowania danych do wykreślenia mapy kosztów budowy sieci transportowej. Przeprowadzono więc szereg symulacji przy fikcyjnych, testowych konfiguracjach mapy kosztów, zmieniając jednocześnie zadane potrzeby transportowe. Za każdym razem uzyskiwano całą rodzinę rozwiązań. Dla sprawdzenia wiarygodności metody dla każdego zestawu danych wejściowych procedura optymalizacyjna była uruchamiana wielokrotnie. Kolejne, niezależne przebiegi procedury optymalizacyjnej dla tych samych danych generowały rodziny o niemal identycznych składach. Oczywiście, poszczególne rozwiązania różniły się nieco szczegółami w kolejnych generacjach, ale wszystkie typy struktur proponowanej sieci transportowej były powtarzalnie otrzymywane. Poniżej przedstawiono wyniki otrzymane dla jednej z map testowych przy różnych natężeniach ruchu. Przy każdej strukturze wypisano unormowaną do jedności wartość funkcji dostosowania, co pozwala w łatwy sposób ocenić jej jakość.




Rys. 3. Otrzymane struktury sieci transportowych

Rysunek 3 przedstawia trzy różne struktury sieci transportowej wygenerowane dla pewnego natężenia ruchu. Sieci a) i b) są do siebie podobne, natomiast sieć c) ma zupełnie odmienną budowę. Daje się zauważyć identyczny kształt połączenia biegnącego do miasta północno – wschodniego w sieciach a) i c) – jest to wynik krzyżowania się pomiędzy podpopulacjami.




Rys. 4. Struktury otrzymane dla trzykrotnie mniejszego natężenia ruchu

Rysunek 4 przedstawia rodzinę struktur wygenerowaną dla natężenia ruchu trzykrotnie mniejszego niż w przykładzie poprzednim. Jak widać otrzymane struktury sieci są tutaj zbliżone, jedynym wyjątkiem jest sieć d). Oczywistym skutkiem zmniejszonej intensywności ruchu jest użycie połączeń o niższej kategorii. Sieci a) i c) są do siebie bardzo podobne, a w sieciach a), b) i d) można zauważyć efekty krzyżowania pomiędzy podpopulacjami w postaci niemal identycznego kształtu połączeń z miastami północno – wschodnim i południowo – wschodnim.



Rys. 5. Struktury otrzymane dla dziesięciokrotnie mniejszego natężenia ruchu

Rysunek 5 przedstawia kolejną rodzinę struktur sieci transportowych, tym razem wygenerowaną dla natężenia ruchu dziesięciokrotnie mniejszego od natężenia wyjściowego. Porównując z sieciami z poprzednich przykładów, również tu można zaobserwować zachowanie ogólnych planów budowy, z tym że połączenia są jeszcze niższych kategorii.



Rys. 6. Struktury otrzymane dla trzykrotnie większego natężenia ruchu

Ostatnia grupa struktur, przedstawiona na rysunku 6 jest wygenerowana przy założeniu natężenia ruchu trzykrotnie większego niż w przykładzie wyjściowym. Przy tak dużej intensywności ruchu pojawiają się pętle i równoległe biegnące połączenia o najwyższych kategoriach. Opłacalne zaczyna być prowadzenie połączeń przez tereny o wysokich kosztach budowy: sieci b) i c). Ze względu na złożoność powstających struktur liczba rośnie liczba otrzymywanych wariantów o wysokich wartościach funkcji dostosowania. Mimo tego bogactwa różnych form również i tu można znaleźć efekty krzyżowania pomiędzy podpopulacjami: b) i c) – połączenie z miastem północno – wschodnim, parami c) i d) oraz b) i e) – część południowa obszaru. Struktury a) i g) oraz d) i f) są parami do siebie podobne pod względem ogólnego planu budowy.

Analiza wszystkich otrzymanych struktur prowadzi do wniosku, że istnieje pewna grupa ogólnych planów budowy pojawiających się w szerokim zakresie natężeń ruchu. Poszczególne struktury należące do tych grup różnią się od siebie szczegółami przebiegu połączeń oraz oczywiście kategorią połączeń.

5. PODSUMOWANIE

W pracy przedstawiono metodę poszukiwania sieci transportowej optymalnej dla analizowanego obszaru przy zadanych potrzebach transportowych. Zastosowanie wyspowego algorytmu genetycznego umożliwia jednocześnie znajdowanie najważniejszych maksimów, reprezentujących różne struktury sieci transportowych realizujące wymagane potrzeby.

Prezentowana metoda pozwala na generowanie struktur sieci transportowych nie tylko przy założeniu potrzeb obecnych i na najbliższą przyszłość. Można też włączyć dane pochodzące z różnych, dużo bardziej niepewnych prognoz długoterminowych. Obserwując pojawiające się ogólne plany budowy, należy wyszukać te, które są najbardziej odporne na

zmiany danych wejściowych. Te rozwiązania spełnią wymagania obecne i jednocześnie będą korzystną bazą do ewentualnej rozbudowy w przyszłości.

Dysponując takimi alternatywnymi rozwiązaniami należy w następnym kroku wybrać jedno z nich do realizacji, przy czym mogą być brane pod uwagę inne względy niż tylko te, które udało się zawrzeć w budowanym modelu.

6. BIBLIOGRAFAIA

- [1] Arabas J., Wykłady z algorytmów ewolucyjnych, WNT, Warszawa 2004
- [2] Borovska P., Lazarova M., Migration policies for island genetic models on multicomputer platform. In *Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications*, pages 143 - 148. IEEE, 2007
- [3] Cantu-Paz. E., *Topologies, migration rates, and multi-population parallel genetic algorithms*. 1999
- [4] Gen M., Altıparmak F., Lin L., A genetic algorithm for two-stage transportation problem using priority-based encoding, *OR Spectrum* 28:337–354 (2006)
- [5] Kim B. J., Kim W., Song B. H., Sequencing and scheduling highway network expansion using a discrete network design model, *Ann Reg Sci* (2008) 42:621–642
- [6] Król A., Pamuła T., Application Of Genetic Algorithm For Designing A Transportation Network With Varying Construction Costs, *proc. of Int. Conf. "AI-METH'2009"*, Silesian University of Technology, Gliwice (2009), pp. 179-187
- [7] Pinninghoff M., Contreras R., Atkinson J., *Using Genetic Algorithms to Model Road Network*, IEEE Computer Society (2008)
- [8] Ratajczak M., *Modelowanie sieci transportowych*, Wydawnictwo Naukowe UAM, Poznań 1999
- [9] Skolicki Z., DeJong K., The influence of migration sizes and intervals on island models. In *GECCO '05: Proceedings of the 2005 conference on Genetic and evolutionary computation*, pages 1295-1302, New York, NY, USA, 2005. ACM.
- [10] US Department of Transportation, *Traffic Assignment*, Washington 1973