

DUALIZM LOGISTYCZNO-KOMBINATORYCZNY ZADANIA KOMIWOJAŻERA

LOGISTIC-COMBINATORIAL DUALISM OF SETTING THE TRAVELLING SALESMAN

Krzysztof FICOŃ

Akademia Marynarki Wojennej
Wydział Dowodzenia i Operacji Morskich

Streszczenie: W pracy został przedstawiony dualny charakter problemu komiwojażera (TPS – Travelling Salesman Problem), który może być jednocześnie rozpatrywany jako utylitarne zadanie transportowe według kryteriów logistycznych oraz jako złożony problem kombinatoryczny optymalizacji dyskretnej. W aspekcie optymalizacyjnym zadanie TSP należy do problemów NP-zupełnych, dla których w ogólności nie istnieją efektywne metody rozwiązań. Ze względu na bardzo szeroki zakres logistycznych aplikacji zadania TSP, dokonano prezentacji najbardziej popularnych metod jego rozwiązania. Szczególną uwagę zwrócono na nowoczesne podejście oparte na metodach sztucznej inteligencji i algorytmach mrówkowych. Klasyczny problem TSP jest szczególnym przypadkiem bardzo ważnego we współczesnej logistyce wielowymiarowego problemu marszrutacji rzutującego m.in. na globalne koszty działalności transportowej i logistycznej.

Abstract: At the work described dual character of the vehicle routing stayed (TPS – Travelling Salesman Problem) which can simultaneously be considered as the utilitarian transport task according to logistic criteria and as a combinatorial many-sided problem of discreet optimization. In the operational research aspect the TSP task is included in problems NP-complete, which in general effective methods of solutions don't exist for. On account of very wide range of logistic applications of the TSP task they made the presentation the most of popular methods of untying him. They paid special attention to the modern attempt based on methods of the artificial intelligence and ant algorithms. The classic TSP problem is a special

case very much important in the contemporary logistics of the multidimensional problem route projecting among others onto total costs of transport and logistic activity.

Słowa kluczowe: algorytmy, logistyka, komiwojażer, metody, optymalizacja.

Keywords: algorithms, logistics, travelling salesman, methods, optimization.

Wprowadzenie – logistyka a badania operacyjne

W zgodnej opinii ekspertów przyjmuje się, że geneza współczesnej logistyki rynkowej wywodzi się z pralogistyki wojskowej, a jej ojczyzną są Stany Zjednoczone – zarówno nowożytnej logistyki wojskowej, jak i cywilnej logistyki rynkowej. Logistyka rynkowa narodziła się formalnie w USA po II wojnie światowej, jako praktyczna aplikacja sprawdzonej w krytycznych warunkach bojowych logistyki wojskowej. Gospodarka rynkowa skwapliwie skorzystała z bogatej teorii i dorobku logistyki wojskowej, adaptując jej technologię dla potrzeb usprawnienia materialnych przepływów fizycznych, tak w skali mikro-, jak i makroekonomicznej (Bozarth, Handfield, 2007).

W pragmatycznym podejściu amerykańskim niemal od samego początku logistyka była postrzegana jako sztuka pokonania czasu i przestrzeni przy spełnieniu określonego kryterium jakości, którym najczęściej był wielokryterialny minimalizacyjny postulat minimalizacji kosztów i maksymalizacji standardów obsługi klienta. Dlatego logistyka rynkowa zaliczona formalnie do nauk o zarządzaniu mocno eksponuje ilościowe aspekty optymalizacji decyzji menedżerskich. W tym sensie logistykę jako wykładnię teoretyczną i praktyczną sztukę zarządzania całym łańcuchem dostaw zalicza się do nauk ilościowych, a niekiedy wprost klasyfikuje się ją do obszaru badań operacyjnych (Radzikowski, Sarjusz-Wolski, 1994).

Według J. Pencza badania operacyjne (*Operational Research*) (...) to dziedzina wiedzy zajmująca się metodami analizy celowych czynności (operacji) i obiektywną oceną decyzji, przy użyciu najczęściej techniki komputerowej (Penc, 1997). Zdaniem T. Pszczołowskiego badania operacyjne to (...) przygotowanie racjonalnej i optymalnej w danych warunkach decyzji, jak zrealizować zamierzone przedsięwzięcie, czyli operację, przy zastosowaniu metod matematyczno-statystycznych, których użycie wymaga najczęściej elektronicznej techniki obliczeniowej (Pszczołowski, 1978). Współczesne techniki operacyjne wykorzystują najbardziej zaawansowane narzędzia matematyki stosowanej, takie jak chociażby programowanie matematyczne bazujące na analitycznych modelach i szczegółowych metodach ich rozwiązywania (Ficoń, 2006).

Na niedoskonałość teorii i metod badań operacyjnych zwraca uwagę T. Saaty, określając badania operacyjne jako (...) sztukę dawania złych odpowiedzi na te praktyczne pytania, na które inne metody dają odpowiedzi jeszcze gorsze (Kozubski, 2000). Oznacza to duży szacunek a zarazem dystans do tych metod, ponieważ decydent w swojej działalności powinien kierować się wynikami uzyskanymi ze stosowania metod badań operacji, ale zweryfikowanymi przez doświadczenie, intuicję i zdrowy rozsądek.

Do najbardziej popularnych metod badań operacyjnych należą rozmaite techniki tzw. programowania matematycznego, które najogólniej można podzielić na programowanie liniowe/nieliniowe, ciągłe/dyskretne, deterministyczne/stochastyczne, jednoetapowe/wieloetapowe, dynamiczne, symulacyjne i inne. Praktyka współczesnych badań operacyjnych coraz częściej korzysta także z dorobku sztucznej inteligencji, zwłaszcza ze zbioru tzw. metod zaliczanych do tzw. inteligencji obliczeniowej obejmujących: zbiory rozmyte, sztuczne sieci neuronowe, algorytmy genetyczne, a ostatnio także metody inteligencji roju, np. algorytmy mrówkowe (Do Tianrui, Yong, 2010). Nieodzownym narzędziem badań operacyjnych jest dziś technologia komputerowa oferująca wiele użytecznych systemów i aplikacji zorientowanych na efektywne rozwiązywanie skomplikowanych zadań analitycznych, w tym także biznesowych (TSPLIB. <http://comopt.ifi.uni-heidelberg.de/software/TSPLIB95/>, dostęp: 15.01.2015).

Biorąc pod uwagę kardynalną zasadę logistyczną *Just in Time*, sprowadzającą się powszechnie do spełnienia tzw. 5 „W” – właściwy czas, miejsce, produkt, ilość, jakość i cena, nietrudno zauważyć, że większość decyzji logistycznych ma charakter ilościowy i najlepiej gdyby były podejmowane za pomocą analitycznych kryteriów i liczbowych wskaźników ocenowych. Definityjne „zarządzanie całym łańcuchem dostaw” dotyczy podejmowania decyzji kompleksowych, a także szczegółowych we wszystkich obszarach działalności logistycznej, a zwłaszcza na etapie organizowania (optymalizacji) strumieni popytu i podaży skwantyfikowanych dóbr materialnych (Bozarth, Handfield, 2007).

Jak większość decyzji biznesowych, także logistyczne są podejmowane w warunkach niepełnej informacji, pod dużą presją czasu i przy ograniczonych zasobach – kadrowych, materiałowych, finansowych. Paradygmat optymalnego sterowania całym łańcuchem dostaw – od pierwotnych źródeł zaopatrzenia aż do końcowego konsumenta, poprzez liczne ogniwa pośrednie – stanowi zasadniczy cel prowadzenia działalności logistycznej. Dominującą procedurą jest tutaj organizacja optymalnych dostaw – np. w sensie zasady *Just in Time* do poszczególnych ogniw tego łańcucha, spełniająca wiele kryteriów ekonomicznych, organizacyjnych, technicznych, a także formalnych (Christopher, 1992).

Problematyka zarządzania łańcuchem dostaw bardzo ściśle wiąże się z takimi procesami, jak: organizacja transportu, gospodarka magazynowa, sterowanie zapasami, badania marketingowe, czy prognozowanie popytu rynkowego. W najwyższym stopniu dotyczy też rynkowych standardów obsługi klienta, zarówno po stronie popytu, jak i podaży, których spełnienie warunkuje utrzymanie pożądanego poziomu konkurencyjności. Rynkowy postulat minimalizacji kosztów logistyki nie powinien obniżać poziomu obsługi, a jedynie stymulować najwyższe standardy podejmowanych decyzji sterujących bezpośrednio procesami logistycznymi. Rosnące koszty procesów transportowo-magazynowych powinny wymuszać optymalną organizację całego łańcucha dostaw na wszystkich jego etapach.

Do jednych z najtrudniejszych zadań należy zarządzanie transportem – zapotrzebowanym, dystrybucyjnym, technologicznym – realizującym dostawy materiałowe do poszczególnych ogniw łańcucha dostaw. Nadrzędnym wymogiem w dobie bardzo intensywnego ruchu towarowego jest planowanie optymalnych tras minimalizujących niebagatelne koszty transportu, szacowane na poziomie 30-50% ogólnych kosztów logistyki. Szczególnym przypadkiem zadania transportowego zaliczanego do ogólnego problemu marszrutacji jest tzw. zagadnienie transportowe (*Transportation Problem*), które polega na zbudowaniu optymalnego planu (harmonogramu) przewozu towarów z miejsca nadania do miejsca odbioru, tzn. takiego, który minimalizuje łączne koszty (lub czas) transportu w całej sieci dostaw. Zadanie transportowe należy do szerokiej klasy problemów decyzyjnych z zakresu marszrutacji przewozów ładunków na określonej trasie przy wykorzystaniu pewnej liczby środków transportowych. W celu rozwiązania klasycznego zadania transportowego wykorzystuje się metody programowania liniowego całkowitoliczbowego, a zwłaszcza specjalnie dedykowany tzw. algorytm węgierski, bazujący na metodzie simpleks. Problem marszrutacji należy do podstawowej problematyki zarządzania operacyjnego flotą środków transportowych w dużej firmie przewozowej (Krawczyk, 1996).

1. Sformułowanie problemu komiwojażera

Najbardziej znanym historycznym zadaniem z zakresu optymalizacji transportu jest słynny problem komiwojażera TPS (*Travelling Salesman Problem*) wywodzący się z nurtu praktycznych potrzeb logistycznych (transportowych), a z uwagi na duże trudności jego rozwiązania, lokowany powszechnie w sferze optymalizacji dyskretnej, jako skomplikowane zadanie kombinatoryczne (Cook, 2012).

Ogólny problem komiwojażera TSP formułujemy następująco: dane jest N miast, a każde dwa z nich połączone są drogą o pewnej długości. W jednym z miast znajduje się komiwojażer (np. współczesny kurier), który chce odwiedzić w celach biznesowych wszystkie miasta w taki sposób, aby w każdym mieście znaleźć się dokładnie jeden raz, a na koniec wędrówki powrócić do miejsca startowego. Naszym celem jest znalezienie najkrótszej możliwej trasy dla komiwojażera, gwarantującej np. minimalne koszty podróży. Możemy więc poszukiwać trasy najkrótszej albo najszybszej, albo najtańszej (Davendra, 2010).


Problem komiwojażera TSP najłatwiej jest analizować za pomocą aparatu teorii grafów. Przedstawiając miasta jako wierzchołki, a łączące je drogi jako łuki (krawędzie), otrzymujemy pewien graf płaski, w którym z każdą krawędzią E_i związana jest liczba rzeczywista, np. odległość wyrażona w kilometrach $W(E_i)$. W teorii grafów taki graf nazywamy ważonym, a $W(E_i)$ jest wagą krawędzi E_i . Jeśli pewna droga zamknięta w grafie zawiera wszystkie krawędzie tego grafu, to tę drogę nazywamy drogą

Eulera, a graf – grafem Eulera. Droga Eulera w grafie spójnym – bez wierzchołków izolowanych – jest więc drogą zamkniętą przechodzącą przez każdą krawędź grafu dokładnie tylko jeden raz (Deo, 1980).

Sprzężonym pojęciem z drogą Eulera jest tzw. obwód (cykl) Hamiltona, pod którym w grafie spójnym określa się drogę zamkniętą, która przechodzi przez każdy wierzchołek tego grafu dokładnie tylko jeden raz, z wyjątkiem wierzchołka początkowego (końcowego), w którym droga ta także się kończy. Nietrudno zauważyć, że obwód Hamiltona w grafie o N wierzchołkach składa się dokładnie z N krawędzi. Innym logicznym faktem jest stwierdzenie, że nie każdy graf spójny ma obwód Hamiltona. Powstaje więc pytanie: jaki jest warunek konieczny i dostateczny na to, aby graf spójny G miał obwód Hamiltona? Problem ten po raz pierwszy postawił w 1859 roku W.R. Hamilton i jak dotąd nie został on rozwiązany. Nie jest znane kryterium, które pozwala na stwierdzenie, że dany graf posiada obwód Hamiltona. Ponieważ dany graf może zawierać więcej niż jeden obwód Hamiltona, powstaje kolejne pytanie – ile obwodów Hamiltona występuje w tym grafie? Podobieństwo między drogą Eulera a obwodem Hamiltona jest złudne, gdyż ten drugi jest nieskończenie bardziej złożony (Kulikowski, 1986).

Dla potrzeb dalszych rozważań wprowadzimy jeszcze pojęcie grafu pełnego, pod którym będziemy rozumieć graf płaski, w którym zawsze istnieje krawędź między każdą parą wierzchołków. Można wykazać, że całkowita liczba różnych (ale nie rozłącznych krawędziowo) obwodów Hamiltona w grafie pełnym o N wierzchołkach wynosi $(N-1)!/2$. Wynika to z faktu, że startując z dowolnego wierzchołka, mamy $N-1$ krawędzi do wyboru z pierwszego wierzchołka, $N-2$ z drugiego wierzchołka, $N-3$ z trzeciego itd. Ponieważ wszystkie wybory są niezależne, otrzymujemy $(N-1)!$ wszystkich możliwych kombinacji. W szczególnym przypadku grafów symetrycznych liczbę wszystkich możliwych kombinacji $(N-1)!$ dzielimy przez 2, ponieważ każdy obwód Hamiltona był liczony dwukrotnie.

Grafy jako obiekty topologii matematycznej można przedstawiać na wiele sposobów, np.: w postaci graficznej sieci zawierającej węzły (wierzchołki) oraz łączące je krawędzie (gałęzie) – rys. 1, a także w postaci tabelarycznej odwzorowującej tzw. macierz koincydencji grafu – tabela 1. Istnieje jeszcze wiele innych sposobów zapisywania grafów, np. w postaci sekwencji zbioru wierzchołków i przypisanych im krawędzi, albo odwrotnie i inne. Jak łatwo zauważyć, przedstawiony na rys. 1 graf pełny $G(6)$, zawierający 6 wierzchołków zawiera teoretycznie $(6-1)!/2 = 60$ możliwych permutacji – obwodów Hamiltona, czyli 30 symetrycznych tras komiwojażera.



Rys. 1. Grafowa interpretacja problemu komiwojażera TSP

Źródło: opracowanie własne

Tabela 1. Macierzowa interpretacja architektury grafu pełnego $G(6)$

	M1	M2	M3	M4	M5	M6
M1	-	X_{21}	X_{31}	X_{41}	X_{51}	X_{61}
M2	X_{12}	-	X_{32}	X_{42}	X_{52}	X_{62}
M3	X_{13}	X_{23}	-	X_{43}	X_{53}	X_{63}
M4	X_{14}	X_{24}	X_{34}	-	X_{54}	X_{64}
M5	X_{15}	X_{25}	X_{35}	X_{45}	-	X_{65}
M6	X_{16}	X_{26}	X_{36}	X_{46}	X_{56}	-

Źródło: opracowanie własne

Tabela 2. Przykładowy cykl Hamiltona w grafie pełnym $G(6)$

	M1	M2	M3	M4	M5	M6
M1	-	X_{12}	•	•	•	•
M2	•	-	•	•	•	X_{26}
M3	X_{31}	•	-	•	•	•
M4	•	•	X_{43}	-	•	•
M5	•	•	•	X_{54}	-	•
M6	•	•	•	•	X_{65}	-

Źródło: opracowanie własne

Przedstawiony powyżej opis dotyczy zadania symetrycznego STSP (*Symmetric TSP*), czyli takiego problemu komiwojażera, gdzie na odległość między dwoma miastami nie ma wpływu kierunek, tzn. odległość z miasta A do miasta B jest taka sama, jak z miasta B do miasta A. Jeśli natomiast odległości między miastami w zależności od kierunku są różne lub nie istnieje droga w dwóch kierunkach, wtedy mamy do czynienia z asymetrycznym problemem komiwojażera ATSP (*Asymmetric TSP*), wówczas wykorzystuje się graf skierowany (Cook, 2012).

Wracając do problemu komiwojażera, możemy zauważyć, że można go „łatwo” rozwiązać przez wyznaczenie wszystkich możliwych $(N-1)!/2$ obwodów Hamiltona i pojedyncze obliczenie ich długości. W ogólności problem TSP sprowadza się do zbadania $(N-1)!/2$ permutacji wszystkich możliwych dróg łączących N miast. Dysponując pełnym zbiorem wszystkich obwodów Hamiltona, nietrudno byłoby znaleźć taki obwód, którego długość jest najmniejsza. Niestety podejście to jest możliwe tylko dla małych wartości N , gdyż przy rosnącej liczbie wierzchołków i zastosowaniu nawet najbardziej wydajnych współczesnych komputerów efektywność tej procedury jest zupełnie zawodna. Zgodnie z wykładniczym charakterem formuły $(N-1)!/2$, czas wykonania tej operacji dla większych wartości N rośnie w sposób wykładniczy i bardzo szybko staje się zupełnie nierealny, co wynika z użytkowej charakterystyki zadań należących do klasy tzw. problemów NP-zupełnych (Coffman, 1980).

Dobitnie świadczy o tym następujące zestawienie. Przy założeniu, że komputer przetwarza milion operacji na sekundę – czas potrzebny na rozwiązanie problemu komiwojażera metodą pełnego przeglądu grafu pełnego, w zależności od liczby miast, wyrażony w mikrosekundach wynosi szacunkowo: dla 10 miast – 10^6 , dla 50 miast – 10^{16} , dla 100 miast – 10^{31} , a dla 300 miast – 10^{623} . Dla porównania liczba mikrosekund od wielkiego wybuchu, w którym narodził się nasz Wszechświat wynosi 10^{24} . Wynika stąd wniosek, że w ogólnym przypadku metoda pełnego przeglądu wszystkich możliwych permutacji $(N-1)!/2$ jest zupełnie nieprzydatna w praktyce i całkowicie irracjonalna.

2. Geneza i perspektywy aplikacyjne zadania TSP

Pierwsze próby naukowego rozwiązania problemu komiwojażera pochodzą jeszcze z XIX w. od matematyków W.R. Hamiltona i T.P. Kirkmana, którzy wykorzystali do tego celu teorię grafów Eulera. Natomiast systematyczne badania problemu TSP zostały zapoczątkowane w roku 1930 przez K. Mengersa, w latach 40. XX w. interesowali się nim statystycy Mahalanobis (1940), Jessen (1942), Gosh (1948). Realne podejście do dróg Hamiltona zostało podjęte w roku 1949 przez J. Robinsona, natomiast przełomowe okazały się pionierskie aplikacje G. Dantzinga, R. Fulkersona i S. Johnsona z roku 1954, które posłużyły do wyznaczenia optymalnej drogi Hamiltona dla przypadku obejmującego 49 miast (Kulikowski, 1986). Dzięki

postępowi naukowo-technicznemu i coraz bardziej zaawansowanym technologiom komputerowym mogły być podejmowane kolejne próby rozwiązania problemu TSP dla coraz większej liczby miast. Wykorzystując najnowsze zdobycze nauki i techniki (programowanie matematyczne, obliczenia równoległe, klastry wielordzeniowe komputerów), naukowcy byli w stanie wyznaczyć rozwiązania dokładne dla zdumiewająco dużej liczby miast N , co obrazuje tabela 3.

Tabela 3. Historia badań i sukcesów nad rozwiązaniem problemu TSP

1954	G. Dantzig, R. Fulkerson, S. Johnson	49
1971	M. Held, R.M. Karp	64
1975	P.M. Camerini, L. Fratta, F. Maffioli	67
1977	M. Grötschel	120
1980	H. Crowder, M.W. Padberg	318
1987	M. Padberg, G. Rinaldi	532
1987	M. Grötschel, O. Holland	666
1987	M. Padberg, G. Rinaldi	2392
1987	D. Applegate, R. Bixby, V. Chvátal, W. Cook	7397
1998	D. Applegate, R. Bixby, V. Chvátal, W. Cook	13 509
2001	D. Applegate, R. Bixby, V. Chvátal, W. Cook	15 112
2004	D. Applegate, R. Bixby, V. Chvátal, W. Cook, K. Helsgaun	24 978

Źródło: opracowanie własne

Jak wynika z tabeli 3, imponujący wynik otrzymano w maju 2004 roku, kiedy zespół D. Applegate, R. Bixby, V. Chvátal, W. Cook znalazł optymalną trasę dla 24 978 miejscowości w Szwecji liczącą łącznie około 72 500 km, będącą trasą najkrótszą (Applegate, Bixby, Chvátal, Cook, 2007). Wykorzystali oni algorytmy programowania liniowego i całkowitoliczbowego, które liczone były równoległe na klastrze obejmującym 96 komputerów posiadających po 2 procesory Intel Xenon 2,8 GHz. Do obliczeń użyto kodu Concorde TSP, rozwiązującego problem za pomocą programowania liniowego metodą simpleksu w wersji 6.5 CPLEX. Z uwagi na to, że do obliczeń wykorzystano klastr, który w tym samym czasie był używany również do przeprowadzenia innych obliczeń, trudno jest podać rzeczywisty czas, jaki zajęły obliczenia. Natomiast w przeliczeniu na jeden procesor, z jakich składa się klastr, całkowity czas wszystkich obliczeń wynosiłby 91,9 lat.

W czasach szybkiego rozwoju cywilizacyjnego, gdzie ciągle szuka się szybszych, lepszych oraz tańszych rozwiązań, problem komiwojażera TSP ze względu na optymalizacyjny charakter ma szerokie zastosowanie nie tylko w praktyce biznesowej. Choć przede wszystkim jest wykorzystywany w dziedzinie logistyki transportu oraz dystrybucji, która jest podstawą funkcjonowania dzisiejszej gospodarki, to jego zastosowania są znacznie szersze. Najbardziej popularna jego aplikacja dotyczy jednego komiwojażera i skończonego cyklu Hamiltona (Kulikowski, 1986).

Oprócz naturalnych aplikacji na gruncie logistyki i transportu, problem TSP znajduje szerokie zastosowanie w wielu innych dziedzinach nauki i praktyki biznesowej, przemysłowej, a także w ambitnych programach naukowo-badawczych, o czym świadczą poniższe przykłady. Makro- i mikrorozwiązanie typu TSP wykorzystywane są powszechnie we współczesnym przemyśle podczas organizacji linii produkcyjnych zapewniających jak najmniejszą rotację, generującą straty czasowe, elementu produkcyjnego przez obrabiające go maszyny. Bardzo wyraźnie problem ten występuje w sterowaniu ruchem robotów odpowiedzialnych m.in. za nawiercanie otworów, spawanie, cięcie oraz inną obróbkę materiałów, części i elementów. Optymalizacja ruchu ramienia robota jest poważnym problemem, który musi być optymalnie rozwiązany na etapie programowania tych czynności. Często ramię lub kiść robota wykonuje miliony ruchów w różnych wymiarach przestrzennych, co pociąga za sobą zużycie odpowiednich reśursów czasowych, funkcjonalnych, zasileniowych, obniżając efektywność eksploatacji bardzo kosztownych linii robotycznych (Ficoń, 2013).

Rozwiązanie typu TSP wykorzystywane jest szeroko w elektronice i mikroelektronice podczas optymalnego planowania architektury i rozmieszczenia obwodów elektrycznych oraz elementów elektronicznych, np. na płytkach montażowych. Problem komiwojażera jest wykorzystywany również w informatyce do optymalizacji tras routingu w sieciach komputerowych oraz w systemach telekomunikacyjnych. Efektywne algorytmy TSP sterują ruchem w sieci Internet i są podstawą funkcjonowania standardowego protokołu transmisji danych TCP/IP. Jako ciekawostkę można podać, że zadanie TSP znalazło zastosowanie także we współczesnej medycynie, np. w analizach mikromacierzy DNA. Problematyka TSP jest stosowana wszędzie tam, gdzie chodzi o optymalizację trasy w sensie minimalizacji drogi, czasu lub innych reśursów zużywanych w danym przedsięwzięciu.

3. Typologia metod rozwiązania problemu TSP

Stosowane dotychczas metody rozwiązania problemu komiwojażera TSP można podzielić na trzy zasadnicze klasy obejmujące (Davendra, 2010):

- metody dokładne (optymalizacyjne) dające rozwiązanie optymalne,
- metody przybliżone (heurystyczne) dające rozwiązanie dopuszczalne, ale niekoniecznie optymalne,
- metody sztucznej inteligencji generujące rozwiązanie dopuszczalne, przybliżone.

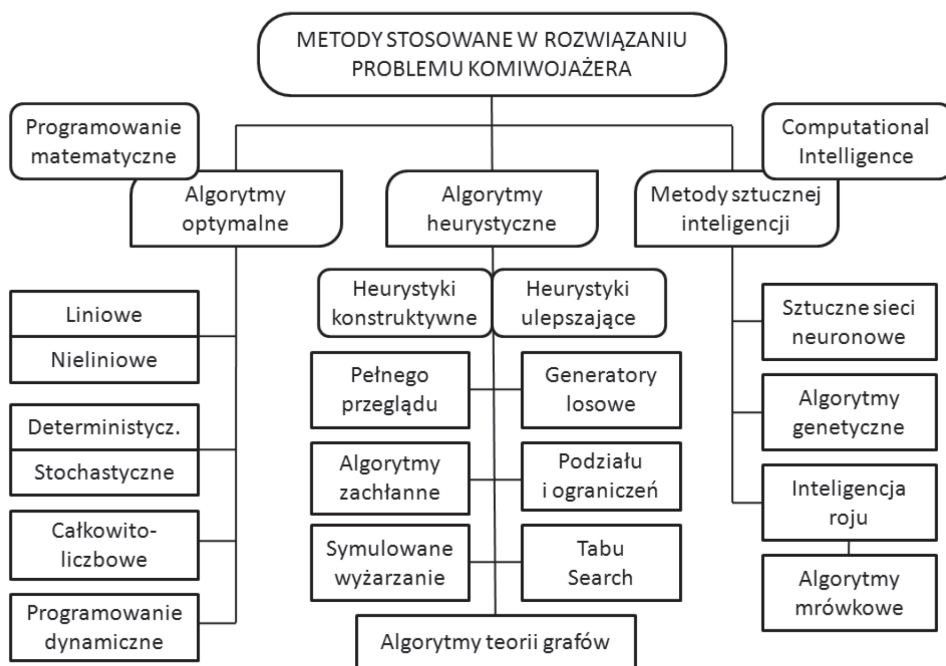
Klasyczne problemy optymalizacyjne (minimalizacyjne) można podzielić na dwie zasadnicze klasy według możliwości ich rozwiązywania. Jeżeli istnieje algorytm, który ze wzrostem rozmiaru problemu rozwiązuje problem w czasie rosnącym tylko wielomianowo (lub wolniej), wtedy mówimy, że jest to problem

wielomianowy i należy do klasy P. Klasa P jest podklasą klasy NP, podobnie jak klasa tzw. problemów NP-zupełnych. Czas potrzebny do rozwiązania problemu NP-zupełnego wzrasta wykładniczo ze wzrostem zmiennych liczby wejściowych (niezależnych), np. N (Coffman, 1980). Ponieważ w przypadku problemu komiwojażera TSP zastosowanie pełnego przeszukiwania przy większej liczbie miast nie jest celowe ani możliwe, gdyż problem ten należy właśnie do klasy NP-zupełnych, w praktyce stosowane są jedynie algorytmy przybliżone (Cormen, Leiserson, Rivest, Stein, 2007). Algorytmy te nie są pozbawione wad, jednak działają w czasie wielomianowym, będącym wielomianem zmiennej niezależnej – liczby odwiedzanych na marszrucie miast. Rozwiązania przybliżone są rozwiązaniami dopuszczalnymi, choć w ogólnym przypadku nie gwarantują minimalizacji (maksymalizacji) funkcji celu.

Historycznie do rozwiązania problemu komiwojażera TSP jako pierwsze zostały wykorzystane klasyczne metody bazujące na teorii grafów, takie jak: metoda dróg elementarnych Hardgrave, Nemhauser, metoda minimalnego szkieletu Held, Karp, czy metoda funkcji kary Christofidesa (Kulikowski, 1986). W dalszej kolejności w nurcie badań operacyjnych podjęto prace nad wykorzystaniem metod optymalizacyjnych, takich jak: programowanie liniowe i całkowitoliczbowe, programowanie dynamiczne, programowanie stochastyczne oraz metody podziału i ograniczeń. Ze względu na NP-zupełną złożoność obliczeniową problemu TSP, pomimo angażowania coraz bardziej wydajnych komputerów metody te mogły być wykorzystane tylko do niewielkich zadań, dla stosunkowo małej liczby miast. Efektywne rozwiązywanie bardziej złożonych zadań TSP umożliwiły dopiero metody przybliżone bazujące na różnych heurystykach i mechanizmach zdroworozsądkowych (Nilsson, 2003). Użyteczne heurystyki, odznaczające się dużą sprawnością obliczeniową, zaliczane są do specjalnej klasy metaheurystyk, spośród których dla potrzeb rozwiązania problemu TSP wykorzystuje się takie metody, jak: *Tabu Search* (Hall, 2012), symulowanego wyżarzania (*Simulated Annealing*) (Metropolis et al., 1953), metody wyszukiwania z nawrotami i inne.

Najbardziej zaawansowane metody przybliżone ewoluują dziś w stronę rozwiązań hybrydowych łączących rozmaite heurystyki z algorytmami optymalizacyjnymi, a także z metodami sztucznej inteligencji, szeroko wykorzystując narzędziowy aparat współczesnej informatyki i nowoczesną technologię komputerową (Do Tianrui, Yong, 2010).

Burzliwy rozwój technologii komputerowej powoduje wzrost zainteresowania tzw. metodami obliczeniowymi sztucznej inteligencji (*Artificial Intelligence*), zwłaszcza grupą tzw. metod inteligencji obliczeniowej (*Computational Intelligence*), do których tradycyjnie zaliczamy: sztuczne sieci neuronowe (*Neural Networks*), algorytmy genetyczne (*Genetic Algorithms*), czy teorię zbiorów rozmytych (*Fuzzy Sets*) (Rutkowski, 2006).



Rys. 2. Typologia metod wykorzystywanych w problemie komiwojażera TSP

Źródło: opracowanie własne

W ostatnich latach burzliwie rozwija się nowy dział metod sztucznej inteligencji bazujący na inteligencji roju (*Swarm Optimization*), których zasady działania zostały zaczerpnięte z obserwacji natury (Clerc, 2000). Metody inteligencji roju SI (*Swarm Intelligence*) naśladując zachowanie osobników żyjących w świecie owadów, ptaków, ryb, a nawet roślin tworzących pewne populacje społeczne, dostarczają wiedzy na temat bardzo wydajnych algorytmów heurystycznych. Do tej klasy algorytmów należą m.in. algorytmy mrówkowe ACO (*Ant Colony Optimization*), algorytmy pszczoły BA (*Bee Algorithms*) i algorytmy roju cząstek PSO (*Particle Swarm Optimization*). W przeciwieństwie do klasycznych metod optymalizacyjnych nie bazują one na pojedynczym rozwiązaniu, lecz na pewnym zbiorze rozwiązań. Metody inteligencji roju stanowią ogromny potencjał do rozwiązywania zagadnień optymalizacji kombinatorycznej, w tym problemu komiwojażera TSP (Clerc, 2000).

4. Metody heurystyczne

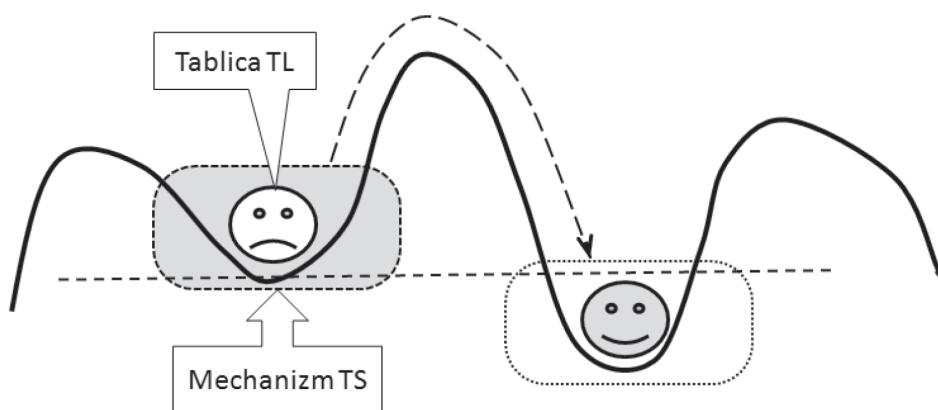
Metody heurystyczne nie gwarantują rozwiązania optymalnego, natomiast charakteryzują się bardzo dużą szybkością, dzięki czemu są z powodzeniem stosowane w rozwiązywaniu praktycznych zadań TSP (Nilsson, 2003). Nowoczesne

metody potrafią znaleźć rozwiązanie dla ogromnych problemów z wielką liczbą miast w rozsądnym czasie, odbiegające zaledwie 2-3% od optymalnego rozwiązania. Jest to dział dosyć obszerny, który możemy podzielić na heurystykę konstruktywną, gdzie rozwiązanie jest sukcesywnie budowane z otrzymanych fragmentów, które nie są modyfikowane przez algorytm oraz heurystykę ulepszającą, w której znajdują się metody ulepszające już istniejące rozwiązanie. Jeszcze inne kryterium dzieli algorytmy heurystyczne na zachłanne i stosunkowo nową kategorię zaliczaną do tzw. *Tabu Search*.

Najprostsze algorytmy heurystyczne budują trasę komiwojażera stopniowo, dodając w każdym kroku kolejne miasto, z reguły z pewnego najbliższego sąsiedztwa. Taka technika choć szybka i prosta, ale nie zawsze gwarantuje efektywne rozwiązanie (Nilsson, 2003). Inne heurystyki poprawiają w kolejnych krokach rozwiązania dopuszczalne z poprzedniego etapu, co pozwala na uzyskanie wielu alternatywnych rozwiązań cechujących się coraz lepszymi parametrami. Nowe trasy mają zawsze pewne części wspólne, będące osnową kolejnych aproksymacji. Opracowane za pomocą heurystyki alternatywne trasy tworzą pewnego rodzaju sąsiedztwo wokół pierwotnej trasy wyjściowej. W kolejnym kroku algorytm wybiera najkrótszą nową trasę z sąsiedztwa, która staje się trasą pierwotną i jest podstawą budowania kolejnego sąsiedztwa. Program kończy swoją pracę, gdy nie ma możliwości zbudowania nowego sąsiedztwa lub gdy każda nowa trasa jest dłuższa od aktualnie wyliczonej.

Taki typ algorytmu nosi nazwę algorytmu zachłannego i niestety nie potrafi samodzielnie rozwiązać tzw. problemu lokalnego maksimum (minimum). Zgodnie z założeniami algorytmu zachłannego osiągnięcie lokalnego minimum blokuje poszukiwanie innego minimum, gdyż nawet chwilowego pogorszenia rozwiązania, w celu opuszczenia tego minimum, nie może zaakceptować ten algorytm. Algorytmy zachłanne programowo zatrzymują się więc na pierwszym napotkanym lokalnym ekstremum – minimum lub maksimum i nie potrafią podjąć poszukiwania kolejnego rozwiązania dopuszczalnego (pierwotnego), w nowym sąsiedztwie optimum lokalnego (Aarts, Lenstra, 2003).

Obiecującą klasą algorytmów heurystycznych, które radzą sobie z zatrzymaniem (stopem) w lokalnym minimum są tzw. metaheurystyki, pozwalające na efektywne opuszczenie lokalnego minimum. Stosunkowo dużym uznaniem cieszy się tzw. metoda *Tabu Search* (TS) autorstwa Freda Glover (1986 r.) oparta na technice przeszukiwania lokalnego sąsiedztwa. Podstawową ideą algorytmu TS jest przeszukiwanie przestrzeni, stworzonej ze wszystkich możliwych rozwiązań, za pomocą sekwencji ruchów i dokumentujących je zapisów w tablicy *Tabu*. W programie sekwencji ruchów istnieją ruchy niedozwolone, czyli tzw. ruchy (strategie) *tabu*, blokowane odpowiednim zapisem na liście *Tabu*. Algorytm TS uniemożliwia oscylację wokół optimum lokalnego dzięki przechowywaniu informacji o sprawdzonych już rozwiązaniach w postaci listy *Tabu* (TL).



Rys. 3. Mechanizm działania metody *Tabu Search* w zadaniach optymalizacyjnych
Źródło: opracowanie własne

Metoda TS bazuje na koncepcji przeszukiwania lokalnego sąsiedztwa, a każde poprawne rozwiązanie (niekoniecznie optymalne) zapisywane jest na liście TL (*Tabu*). Lista ta zawiera zbiór ostatnich zmian trasy pierwotnej, które blokują powrót do optimum lokalnego. Aby wydostać się z pułapki optimum lokalnego, na podstawie przeglądu listy TL wybierane jest rozwiązanie gorsze od aktualnego optimum. Aby uniemożliwić ponowny powrót do lokalnego optimum, program sprawdza, czy dana trasa znajduje się w rejestrze tras zabronionych listy TL. Jeśli tak, to taka zmiana jest niedozwolona i zostaje wybrana inna nowa trasa z aktualnego sąsiedztwa, aby możliwe było skuteczne opuszczenie lokalnego optimum. Technika *Tabu Search* okazała się bardzo skuteczna przy modyfikacji algorytmów zachłanych, będących punktem startowym większości algorytmów heurystycznych (Glover, 1986).

5. Metody sztucznej inteligencji

Klasyczne metody obliczeniowe sztucznej inteligencji (*Soft Computational*), tj. sztuczne sieci neuronowe i algorytmy genetyczne niemal od pierwszych chwil swoich narodzin (lata 70. XX w.) były aktywnie wykorzystane przy próbach efektywnego rozwiązania problemu TSP (Duch, Mandziuk, 2011).

Sztuczne sieci neuronowe (NN – *Neural Networks*) są to modele logiczno-matematyczne, budowane na wzór ludzkiego neuronu i służące do przetwarzania informacji w zakresie efektywnego rozwiązywania pewnych zadań teoretycznych i praktycznych. Formalnie realizują przetwarzanie informacyjnych sygnałów wejściowych według określonego algorytmu działania w celu uzyskania pożądanego wyniku na wyjściu. Najczęściej pojedyncze neurony są łączone z reguły w trójwarstwową sieć reprezentującą dostatecznie złożony system przetwarzania informacji (Kosiński, 2007).

Kluczem do sukcesu w rozwiązywaniu problemu TSP za pomocą sztucznych sieci neuronowych jest zaproponowanie odpowiedniej notacji reprezentującej dane wejściowe – strukturę grafu obrazującego konkretny problem. Tradycyjnie każde miasto jest reprezentowane za pomocą wiersza zawierającego N neuronów. W takim wierszu dokładnie jeden neuron powinien przyjmować wartość „1”, a wszystkie pozostałe ustawione są na wartość „0”. Pozycja do 1 do N , na której występuje neuron sygnalizujący wartość „1”, odpowiada kolejności, w jakiej to właśnie miasto ma być odwiedzane przez komiwojażera. A zatem „1” na pierwszej pozycji oznacza, że dane miasto będzie odwiedzane w pierwszej kolejności. Z kolei „1” na drugiej pozycji oznacza, że dane miasto będzie odwiedzane jako drugie w kolejności przez komiwojażera itp. Liczba wierszy odpowiada liczbie miast znajdujących się na trasie komiwojażera. Dla odzwierciedlenia struktury grafu komiwojażera należy zbudować sieć zawierającą łącznie N^2 neuronów, które powinny być zgrupowane w odpowiednich warstwach. Każdy neuron w takiej sieci musi być indeksowany dwoma wskaźnikami. Pierwszy z nich dotyczy numeru miasta, a drugi kolejności, w jakiej to miasto powinno być odwiedzane przez komiwojażera (Tadeusiewicz, 1993).

Zasadniczą zaletą sztucznych sieci neuronowych NN jest fakt, że pracujące równoległe neurony mogą rozwiązywać postawiony problem TSP w stosunkowo krótkim czasie, mimo jego niewielomianowej NP-zupełnej złożoności obliczeniowej. Należy także podkreślić, że wzrost rozmiaru zadania (liczby miast) będzie w tym przypadku wymagał jedynie rozbudowy sztucznej sieci neuronowej, a nie będzie powodował wydłużenia czasu obliczeń, jak w przypadku innych metod rozwiązujących problem TSP.

Algorytmy genetyczne (GA – *Genetic Algorithms*) zaliczane są do szerszej klasy programowania ewolucyjnego i naśladują pewne mechanizmy ewolucji przyrodniczej w celu znalezienia pożądanego rozwiązania optymalnego. Formalnie algorytm genetyczny GA przeszukuje skończoną przestrzeń alternatywnych rozwiązań danego problemu w celu znalezienia rozwiązania najlepszego. W procesie generowania tego rozwiązania wykorzystuje naturalne mechanizmy selekcji, krzyżowania i mutacji, jako algorytmiczne procedury doskonalące dotychczasowe rozwiązanie dopuszczalne (Holland, 1975).

Do opisu algorytmów genetycznych GA wykorzystuje się terminy zapożyczone z genetyki naturalnej. Algorytm bazuje na populacji, która składa się ze zbioru osobników reprezentujących rozwiązanie. Dowolny osobnik zbudowany jest z zespołu chromosomów, z których każdy jest uporządkowanym zbiorem genów (genom). Gen natomiast jest najmniejszą jednostką informacji genetycznej i reprezentuje pojedynczą cechę osobnika. Wartości genu są nazywane allelami i w przypadku gdy gen jest wartością binarną, to jego allelami są wartości 0 lub 1. Potencjalne rozwiązanie zadania reprezentuje genotyp, czyli zespół chromosomów opisujących osobnika. Poza genotypem każdy osobnik jest charakteryzowany przez fenotyp, który stanowią rzeczywiste cechy określające jego stopień przystosowania na tle innych osobników w danej przestrzeni rozwiązań (Arabas, 2004).

Podstawą działania algorytmu genetycznego GA jest cykliczne powtarzanie operacji mającej na celu tworzenie nowych, lepiej przystosowanych osobników zgodnie z tzw. standardowym algorytmem genetycznym Hollanda (SGA – *Simple Genetic Algorithm*) (Holland, 1975). Punktem startowym algorytmu SGA jest tworzenie osobników stanowiących populację początkową. Trasa każdego osobnika jest wybierana w sposób zupełnie losowy poprzez losowanie kolejnego punktu na trasie z danej listy wszystkich punktów. Po każdym wyborze, wybrany punkt jest usuwany z listy w celu uniknięcia powstania trasy niedopuszczalnej (trasa przebiega przez każde miasto tylko raz). Następnie ocenia się przystosowanie osobników. W problemie komiwojażera pojedynczy chromosom reprezentuje konkretną trasę podróży, czyli kolejność odwiedzanych miast. Od rodzaju reprezentacji zależy później sposób zastosowania operatorów krzyżowania oraz mutacji. Chromosom najlepiej przystosowany będzie reprezentował trasę o najkrótszej drodze. Każdy punkt jest reprezentowany za pomocą współrzędnych geograficznych w przestrzeni dwuwymiarowej, a całkowita droga jest sumą odległości euklidesowej pomiędzy kolejnymi punktami na trasie. Do kalkulacji odległości algorytm SGA wykorzystuje macierz, która przechowuje obliczone odległości pomiędzy wszystkimi punktami (Ramani, 2011).

6. Algorytmy mrówkowe

Algorytm mrówkowy (ACO – *Ant Colony Optimization*) należący do grupy metod zaliczanych do inteligencji roju (SI – *Swarm Intelligence*) jest przeznaczony do heurystycznego wyszukiwania najlepszych (optymalnych) ścieżek w grafach, w szczególności znajdowania cykli Hamiltona. Inspiracja pochodzi ze świata mrówek, które potrafią znaleźć najkrótszą trasę między mrowiskiem a pożywieniem. Początkowo mrówki wędrując w stronę pożywienia, obierają drogę losowo, ale wracając do mrowiska, w drodze powrotnej pozostawiają na swojej trasie tzw. ślad feromonowy (Dorigo, Maniezzo, Coloni, 1996).

Feromony stopniowo parują, co powoduje utratę cennej informacji. Na krótszej trasie intensywnie uczęszczanej przez mrówki parowanie jest stosunkowo wolniejsze niż na innych mniej uczęszczanych trasach. W efekcie kolejne mrówki wybierają tę krótszą trasę chętniej niż inne trasy. Kiedy zostanie znaleziona najkorzystniejsza dla mrówek trasa, kolejne mrówki wybierają ją chętniej, wzmacniając ślad feromonowy. Jest to znane z teorii sterowania zjawisko pozytywnego sprzężenia zwrotnego. Korzystna ścieżka staje się coraz bardziej atrakcyjna dla danej kolonii mrówek. Mniej korzystne trasy tracą na znaczeniu, gdyż ulatniający się ślad feromonowy powoduje coraz mniejszą aktywność mrówek.

Inteligencja mrówek polega na interaktywnych relacjach między kolonią mrówek, które dzielą się zdobytym doświadczeniem na etapie poszukiwania i wykorzystania najkrótszej trasy. W miarę upływu czasu mrówki wspólnie wypracowują pewien

zbiór najkrótszych ścieżek wiodących do określonych celów. Strategia wędrówek mrówek (agentów) oparta jest więc na inteligencji zbiorowej (stadnej). Działanie poszczególnych agentów w takim systemie oparte jest na działaniu pojedynczych mrówek poszukujących niezbędnych dla ich wegetacji zasobów. Każdy agent takiego systemu (mrówka) realizuje identyczną strategię poszukiwania najbardziej korzystnej drogi do celu.

Z przedstawionej koncepcji intuicyjnie rodzi się pomysł wykorzystania algorytmu mrówek ACO albo strategii wieloagentowej do rozwiązania problemu komiwożacza. Ogólny zarys tej metody obejmuje następujące etapy (Dorigo, Stützle, 2004).

1. Tworzona jest populacja mrówek, której rozmiar jest jednym z parametrów algorytmu.
2. Pojedyncza mrówka wybiera swoją ścieżkę niezależnie (losowo) od reszty populacji.
3. Dla każdej mrówki generowane jest losowo miejsce startowe (miasto), z którego rozpoczyna wędrówkę.
4. Formalnie mrówki poruszają się po grafie (sieci), szukając sekwencji wierzchołków grafu tworzącej najkrótszą drogę od wierzchołka startowego do końcowego.

Aby ukierunkować przypadkowe błędzenie i wyeliminować wielokrotne odwiedzenie tych samych wierzchołków, każda mrówka została wyposażona w podręczną pamięć, w której przechowuje listę odwiedzanych wierzchołków. Na starcie lista ta jest pusta, natomiast po dojściu do celu zawiera sekwencję odwiedzanych wierzchołków, w kolejności ich odwiedzania. Lista ta jest tworzona na podstawie śladu feromonowego znaczącego trasę przemarszu każdej mrówki. Poszczególne krawędzie grafu są etykietowane śladem feromonowym. Przy wyborze kolejnej marszruty po pierwsze mrówka nie uwzględnia wierzchołków już odwiedzonych, a po drugie kieruje się bardziej aktywnym śladem feromonowym pozostawionym przez mrówki, które wybrały już tę trasę. Wybór kolejnego odcinka jest więc losowy, ale zgodny z zasadą – im więcej feromonu znajduje się na danej krawędzi, tym większe jest prawdopodobieństwo wyboru danej trasy przez mrówkę.

Algorytm mrówkowy ma charakter iteracyjny. Po zakończeniu bieżącej iteracji każda mrówka czeka na wyznaczenie nowego węzła (miasta) startowego, z którego w następnej iteracji ponownie wyruszy na trasę poszukiwań. W procedurze iteracji bardzo istotny jest fakt gromadzenia feromonu w miarę upływającego czasu na poszczególnych krawędziach grafu. Jednocześnie w miarę upływu czasu, czyli w zależności od liczby wykonywanych iteracji, feromon na ścieżkach mniej uczęszczanych bardziej paruje niż na szlakach intensywnie odwiedzanych. Aktualizacja poziomu (śladu) feromonu uwzględnia zarówno procesy składania odpowiedniej porcji przez mrówki poruszające się po danej marszrucie, jak i jego odparowanie w wyniku mniej intensywnego ruchu na danym odcinku. Strategiczny ślad feromonowy jest

dynamicznie budowany przez całą populację mrówek podczas kolejnych iteracji algorytmu (Dorigo, Maniezzo, Colorni, 1996).

Nietrudno zauważyć, że w trakcie działania algorytmu mrówkowego żadna informacja „nawigacyjna”, która jest niezbędna w efektywnym wyborze trasy nie jest gromadzona w mrówkach. Informacja użyteczna dla poszczególnych mrówek (agentów) jest przechowywana i aktualizowana na poszczególnych krawędziach grafu w postaci mniej lub bardziej aktywnego śladu feromonowego. Rola mrówek polega na wyborze kolejnych odcinków trasy na podstawie ilości feromonu złożonego na danym odcinku (krawędzi) oraz na systematycznym znakowaniu wybranego odcinka własnym śladem feromonowym. Najważniejszą informacją w algorytmie mrówkowym będącą jednocześnie rozwiązaniem problemu komiwojażera jest zbiór krawędzi grafu (marszruta) zawierających najwyższą wartość śladu feromonowego. Rozwiązanie optymalne jest superpozycją najbardziej aktywnych śladów feromonowych wszystkich mrówek (agentów) tworzących daną populację.

Uwagi i wnioski końcowe

W burzliwych czasach globalizacji gospodarki światowej dużym zainteresowaniem cieszą się tzw. wielowymiarowe zadania TPS dotyczące już nie pojedynczego handlowca, ale wielkich sieci dystrybucji obsługiwanych przez profesjonalne firmy kurierskie, dysponujące wielką flotą rozmaitych pojazdów. Organizacyjnie sprawna i ekonomicznie efektywna profesjonalna usługa kurierska w ogólnym przypadku dotyczy rozległych przestrzennie obszarów całych państw, wspólnot gospodarczych, a nawet kontynentów, na których istnieje wiele podmiotów prowadzących różnorodną działalność gospodarczą, której podstawą jest intensywna wymiana handlowa. Warunkiem koniecznym tej wymiany jest optymalnie zorganizowana sieć handlowa, której funkcjonowanie determinują różne modele transportowe, dystrybucyjne, w szczególności zadania typu TSP rozwiązywane za pomocą różnych metod i technologii (Krawczyk, 1996).

Przykładowo, jedna światowa firma kurierska obsługuje w wymiarze globalnym tysiące klientów zarówno po stronie podażowej, jak i popytowej i wiele różnych pośredników za pomocą ogromnej floty transportowej obsługiwanej przez setki operatorów i spedytorów. Bardzo często jest to transport intermodalny wykorzystujący różne gałęzie i środki transportowe, a świadczone usługi muszą spełniać rygorystyczne normy prawne, fiskalne, celne i inne regulacje społeczne, środowiskowe itp. W efekcie wykonanie jednego zlecenia handlowego stanowi ogromny problem menedżerski, który zawsze kończy się suboptymalnym planem i szczegółowym harmonogramem realizacji tego zlecenia (Christopher, 1992).

Ze względu na bardzo intensywne przepływy fizyczne, w których bierze udział wiele podmiotów gospodarczych, tradycyjne „ręczne” projektowanie, planowanie

i harmonogramowanie takich przedsięwzięć jest mało efektywne, a wykorzystywane systemy informatyczne nie zawsze spełniają wszystkie oczekiwania decydentów. Merytoryczną platformą funkcjonowania tych systemów są oczywiście skomputeryzowane aplikacje procesów biznesowych, podstawą działania których są matematyczne modele optymalizacyjne, w szczególności modele transportowe, których racjonalnym jądrem są wielowymiarowe zadania komiwojażera TSP.

W światowych sieciach kurierskich funkcjonują często tysiące multimodalnych kurierów-komiwojażerów, którzy w różnym stopniu optymalizują swoje trasy albo w trybie firmowym, za pomocą odpowiedniej aplikacji komputerowej, albo w trybie indywidualnym, kierując się wiedzą zdroworozsądkową, doświadczeniem i latami praktyki. Bardzo często intuicyjne, heurystyczne rozwiązania doświadczonych operatorów logistycznych czy poszczególnych spedytorów, kurierów i kierowców są wystarczające do opracowania i wdrożenia suboptymalnego harmonogramu obsługi danej trasy (Bozarth, Handfield, 2007).

W praktyce logistycznej najczęściej wymiary, zwłaszcza indywidualnego zadania optymalizacyjnego lokalnego problemu TSP, nie są zbyt wielkie i często wystarczy zdroworozsądkowe rozwiązanie heurystyczne poparte wiedzą i praktycznym doświadczeniem, a głównie znajomością zwyczajów poszczególnych klientów, znajomością terenu, specyfiki lokalnej sieci komunikacyjnej, warunków pogodowych itp. W świetle powyższych uwag nasuwa się logiczny wniosek, że arcytrudne z matematycznego punktu widzenia zadanie komiwojażera TSP wielu biznesmenów i operatorów rozwiązuje rutynowo stosunkowo sprawnie i efektywnie na miarę swoich lokalnych warunków i indywidualnych potrzeb (Bozarth, Handfield, 2007).

Sformułowany powyżej problem komiwojażera TSP jest w aspekcie proceduralnym typowym zadaniem decyzyjnym, z jakim niemal codziennie muszą radzić sobie przede wszystkim menedżerowie logistyki i w tym sensie jest to klasyczne zadanie logistyczne. Z drugiej jednak strony, efektywne jego rozwiązanie leży poza sferą logistyki i już dla niewielkich rozmiarów danych wejściowych wymaga wykorzystania zaawansowanych metod kombinatoryki, teorii algorytmów, teorii grafów, a także szczegółowych metod i algorytmów programowania matematycznego, a ostatnio innowacyjnych metod i algorytmów sztucznej inteligencji. Burzliwy rozwój nauki, technologii i życia gospodarczego wymaga posługiwania się coraz bardziej zaawansowanymi metodami badawczymi, których szczególnym przypadkiem jest NP-zupełny problem komiwojażera, czekający ciągle na formalne, naukowe rozwiązanie.

LITERATURA

- [1] AARTS E., LENSTRA J. (2003), *Local search in combinatorial optimization*, John Wiley & Sons.
- [2] APPLGATE D.L., BIXBY R.E., CHVÁTAL V., COOK W.J. (2007), *The Traveling Salesman Problem: A Computational Study*, Lanchester Prize, Princeton University Press.

- [3] ARABAS J. (2004), *Wykłady z algorytmów ewolucyjnych*, WNT, Warszawa.
- [4] BOZARTH C., HANDFIELD R.B. (2007), *Wprowadzenie do zarządzania operacjami i łańcuchem dostaw*, Helion S.A., Gliwice.
- [5] CHRISTOPHER M. (1992), *Logistyka i zarządzanie łańcuchem podaży*, Wyd. PSB, Kraków.
- [6] CLERC M. (2000), *Discrete Particle Swarm Optimization Illustrated by the Travelling Salesman Problem*.
- [7] COFFMAN E.C. (red.) (1980), *Teoria szeregowania zadań*, WN-T, Warszawa.
- [8] COOK W.J. (2012), *In Pursuit of the Traveling Salesman: Mathematics at the Limits of Computation*, Princeton University Press.
- [9] CORMEN T.H., LEISERSON CH.E., RIVEST R.L., STEIN C. (2007), *Wprowadzenie do algorytmów*, WN-T, Warszawa.
- [10] DAVENDRA D. (2010), *Traveling Salesman Problem, Theory and Applications*, InTech.
- [11] DEO N. (1980), *Teoria grafów i jej zastosowanie w technice i informatyce*, Warszawa, PWN.
- [12] DO TIANRUI R., YONG L.X. (2010), *Computational Intelligence*, World Scientific Publishing Company.
- [13] DORIGO M., MANIEZZO V., COLORNI A. (1996), *The Ant System: Optimization by a colony of cooperating agents*, IEEE Transactions on Systems, Man, and Cybernetics – Part B, 26 (1).
- [14] DORIGO M., STÜTZLE T. (2004), *Ant Colony Optimization*, MIT Press.
- [15] DUCH W., MANDZIUK J. (2011), *Challenges for Computational Intelligence*, Springer.
- [16] FICOŃ K. (2006), *Badania operacyjne stosowane. Modele i aplikacje*, BEL Studio, Warszawa.
- [17] FICOŃ K. (2013), *Sztuczna inteligencja. Nie tylko dla humanistów*, BEL Studio, Warszawa.
- [18] GLOVER F. (1986), *Future Paths for Integer Programming and Links to Artificial Intelligence*, Computer and Operations Research, vol. 13, no. 5.
- [19] HALL S.N. (2012), *A Group Theoretic Tabu Search Approach to the Traveling Salesman Problem*, Biblioscholar.
- [20] HOLLAND J.H. (1975), *Adaptation in Natural and Artificial Systems*, University of Michigan Press.
- [21] KOSIŃSKI R.A. (2007), *Sztuczne sieci neuronowe. Dynamika nieliniowa i chaos*, WNT, Warszawa.
- [22] KOZUBSKI J.J. (2000), *Wprowadzenie do badań operacyjnych*, Wyd. UG, Gdańsk.
- [23] KRAWCZYK S. (1996), *Badania operacyjne dla menedżerów*, Wyd. AE, Wrocław.
- [24] KULIKOWSKI J.J. (1986), *Zarys teorii grafów. Zastosowania w technice*, PWN, Warszawa.
- [25] KWAŚNICKA H. (1999), *Obliczenia ewolucyjne w sztucznej inteligencji*, Wyd. PW, Wrocław.
- [26] METROPOLIS N. et al. (1953), *Equation of State Calculations by Fast Computing Machines*, The Journal of Chemical Physics 21 (6), 108.
- [27] MICHAŁEWICZ Z. (1998), *Algorytmy genetyczne + struktury danych = programy ewolucyjne*, WNT, Warszawa.

- [28] NILSSON C. (2003), *Heuristics for the traveling salesman problem*, Department of Computer Science, Linkoping University.
- [29] PENC J. (1997), *Leksykon biznesu*, AW Placet, Warszawa.
- [30] PSZCZOŁOWSKI T. (1978), *Mała encyklopedia prakseologii i teorii organizacji*, Ossolineum, Wrocław – Warszawa – Kraków – Gdańsk.
- [31] RADZIKOWSKI W., SARJUSZ-WOLSKI Z. (1994), *Metody optymalizacji decyzji logistycznych*, Wyd. UW, Toruń.
- [32] RAMANI G. (2011), *Travelling Salesman Problem (TSP) optimization through Genetic Algorithm: Improvised solution to VLSI Detailed Routing and National Tour* Paperback – September 8.
- [33] RUTKOWSKI L. (2006), *Metody i techniki sztucznej inteligencji*, WN PWN, Warszawa.
- [34] TADEUSIEWICZ R. (1993), *Sieci neuronowe*, Akademicka Oficyna Wydawnicza RM.
- [35] TSPLIB. <http://comopt.ifl.uni-heidelberg.de/software/TSPLIB95/> (15.01.2015).