

KUBEK Daniel¹

Zastosowanie optymalizacji odpornej w problematyce wyznaczania tras pojazdom - charakterystyka oraz kierunki badań

WSTĘP

W rzeczywistych problemach transportowych występowanie niepewności danych jest zjawiskiem powszechnym i naturalnym. Niepewność danych o ruchu drogowym wynika z faktu, że nie jest możliwe precyzyjne określenie wartości danych na etapie planowania procesu transportowego np. podczas wyznaczania tras pojazdom. Dokładne rzeczywiste wartości zawsze są uzyskiwane po fakcie, czyli automatycznie stają się danymi historycznymi. Stosowanie danych historycznych do planowania przyszłych procesów rzeczywistych zawsze będzie obarczone niepewnością, ponieważ nie ma stu procentowej pewności, że zmiana wartości danego parametru będzie mieć dokładnie taki sam przebieg jak to miało miejsce poprzednio. Wobec czego niepewność danych wynika z natury i charakterystyki opisywanego zjawiska będzie oznaczać niemożliwość ustalenia dokładnych, przyszłych wartości danych w trakcie procesu decyzyjnego. W problematyce wyznaczania tras podstawowymi danymi są informacje o czasach przejazdu, które w bardzo wysokim poziomie są wrażliwe na zmiany swoich wartości.

Nieuwzględniona niepewność danych na etapie planowania może skutkować wygenerowaniem rozwiązania, które przy rzeczywistej realizacji będzie przynosić zbędne koszty. W pracy [7] przedstawiono analizę problemów programowania liniowego z bazy danych NETLIB, z której wynika, że nawet niewielka zmiana wartości danych wejściowych - 0,01%, powodowała niezachowanie ograniczeń problemu nawet o 210%. Ograniczeniem dla problematyki marszrutyzacji pojazdów może być na przykład, przyjazd pojazdu do klienta w odpowiednim oknie czasowym. Przykład wpływu wahań parametrów modelu przedstawiono w pracy [2], gdzie analizowano zagadnienie wyznaczania tras pojazdom z oknami czasowymi (ang. Vehicle Routing Problem with Time Windows). Zmiana czasu przejazdu o 1% powodowała, że otrzymane rozwiązanie zmieniało się, czego konsekwencją była zmiana kolejności odwiedzanych klientów. Fakt ten z pewnością jest istotny z punktu widzenia przedsiębiorstwa, jego kosztów realizacji transportu jak również z punktu widzenia poziomu obsługi klientów. Założenie, że dysponowane dane o ruchu miejskim są w stu procentach pewne jest założeniem błędnym i niemającym żadnego uzasadnienia w rzeczywistości.

Jednym z rozwiązań radzenia sobie z niepewnością danych może być teoria optymalizacji odpornej (ang. robust optimization). Poniższy artykuł przedstawia ogólną charakterystykę tej dziedziny oraz jej dotychczasowe zastosowanie w problematyce wyznaczania tras pojazdom (ang. Vehicle Routing Problem - dalej VRP). Jak się okazuje, na podstawie przeglądu literatury, optymalizacja odporna jest obecnym trendem w badaniach nad problematyką VRP.

1. ŹRÓDŁO NIEPEWNOŚCI DANYCH O RUCHU DROGOWEGO

Jak już wspomniano, niepewność danych o procesach i obiektach występujących w systemie transportowym miasta jest zjawiskiem naturalnym. Wynika to z podstawowych cech i własności systemów transportowych miasta, jakimi są (w oparciu o [1]):

- system dużej skali, składa się z wielu obiektów oraz podsystemów, między którymi występują relacje oraz sprzężenia zwrotne,
- występowanie wielu klas użytkowników, których interakcje i zachowania komunikacyjne są często oparte o stan psychofizyczny użytkowników,

¹ Politechnika Krakowska, Wydział Inżynierii Lądowej, Instytut Zarządzania w Budownictwie i Transporcie, Zakład Transportu; e-mail: dkubek@pk.edu.pl

- występowanie złożonych zjawisk ruchowych, które charakteryzują się losowością oraz nieokreślonością np. incydenty drogowe,
- wysoki dynamizm występowania zjawisk, np. tworzenie się zatorów ulicznych.
- podatność na działania zewnętrzne, np. warunki atmosferyczne istotnie zmieniają zachowania kierowców, co z kolei widocznie wpływa na płynność oraz intensywność ruchu drogowego.

W celu właściwego planowania procesów transportowych, tj. wyznaczenia tras pojazdom, które wykonają obsługę towarową danego obszaru miasta, konieczne jest uwzględnienie wspomnianych własności w tymże procesie decyzyjnym. Przytoczone powyżej czynniki mogą wpływać na zmianę czasów przejazdów, wobec czego przyjmowanie w procesie planowania, że posiadane dane są dokładne i pewne jest niepoprawne i nieodpowiadające rzeczywistości.

Istotnymi informacjami niezbędnymi do właściwego zaplanowania trasy pojazdu są m.in. czas przejazdu danego odcinka sieci drogowej, czy też prędkość przejazdu. Przy obecnym postępie technologicznym rozwoju urządzeń pomiarowych ruchu drogowego, pozyskanie takich informacji nie stanowi większych problemów. Jednakże, niezależnie od sposobu wykonania pomiaru, każdy pozyskany zbiór danych o ruchu drogowym będzie obciążony pewną dozą niepewności. Źródłem tej niepewności danych w procesie planowania przewozów są m.in.:

- błąd pomiaru urządzeń technicznych,
- błąd estymacji metody prognostycznej, zastosowanej do oszacowania wartości przyszłych, np. czasu przejazdu danego odcinka.

Kolejnym źródłem niepewności podczas planowania tras przejazdu jest sama implementacja uzyskanego rozwiązania w drodze obliczeń komputerowych [6]. Dla przykładu, w drodze optymalizacji problemu marszrutyzacji otrzymano harmonogram odjazdów poszczególnych pojazdów z magazynu głównego, gdzie dokładność rozwiązania jest, co do jednej minuty. W rzeczywistości pojazd może wyruszyć z bazy kilka minut wcześniej bądź kilka minut później, czego powodem może być np. zawodność środków technicznych, stan psychofizyczny kierowcy, czy też warunki pogodowe. Stąd wpływ rzeczywistości na realizację otrzymanego rozwiązania zawsze będzie tworzyć pewnego rodzaju niepewność poprawności implementacji tego rozwiązania.

Przedstawiona powyżej krótka charakterystyka prowadzi do wniosku, że stosowanie metod modelowania matematycznego bez uwzględnienia niepewności danych w problemach rzeczywistych nie ma większego uzasadnienia.

2. OPTIMALIZACJA ODPORNA - KRÓTKA CHARAKTERYSTYKA

Model matematyczny, w którym występują dane niepewne to niepewny model matematyczny (ang. uncertain model/formulation). Uzyskane rozwiązanie jest tzw. rozwiązaniem odpornym (ang. robust solution), które charakteryzuje się poziomem konserwatyzmu (ang. conservatism level). Poziom konserwatyzmu rozwiązania oznacza, w jakim stopniu dane rozwiązanie jest odporne na wahania parametrów modelu. Dla przykładu, jeśli w modelu problemu VRP przyjmujemy, że czas przejazdu jest parametrem niepewnym i przyjmuje wartości z zakresu [100%, 150%] wartości przeciętnej, to uzyskane odporne rozwiązanie takiego problemu będzie uodpornione na fluktuacje tego parametru w zakresie, jaki został założony w modelu, czyli [100%, 150%]. Dodatkową zaletą takiego rozwiązania jest informacja o tym, kiedy powinno się uruchomić procedurę ponownego przeliczenia trasy lub re-marszrutyzacji (ang. rerouting vehicle problem), w celu ustalenia nowej, aktualnej kolejności odwiedzania klientów.

Opisywanie niepewnych modeli matematycznych może być uzyskane poprzez dwa podejścia:

1. Podejście stochastyczne (ang. Stochastic Approach),
2. Podejście odporne (ang. Robust Approach),

W metodologii stochastycznej zakłada się, że dane modelu mogą mieć naturę losową, a rozwiązanie takiego modelu uzyskiwane jest przez optymalizację stochastyczną (ang. Stochastic Optimization). Zastosowanie podejścia stochastycznego w rzeczywistych obiektach jest właściwe, jeśli spełnione są trzy warunki [6] [8]:

1. Jeżeli dane niepewne modelu wykazują naturę stochastyczną (są losowe),

2. Jeżeli decydent (lub ekspert) procesu decyzyjnego potrafi wskazać właściwy rozkład prawdopodobieństwa, któremu będą odpowiadać wszystkie losowe wahania parametrów modelu,
3. Jeżeli decydent procesu decyzyjnego jest w stanie zaakceptować gwarancje zachowania ograniczeń problemu, jakie uzyska się z programowania stochastycznego (ang. Chance Constraint Programming),
4. Jeżeli proces zdefiniowany jako problem programowania stochastycznego cechuje się dostępnością obliczeniową² (ang. computationally trackable).

Przedstawione warunki są zbyt restrykcyjne dla rzeczywistych procesów transportowych. Po pierwsze, w celu opisanego dowolnego losowego zjawiska rzeczywistego poprzez odpowiedni wielowymiarowy rozkład prawdopodobieństwa jest potrzebna bardzo duża (często nierzeczywista) liczba obserwacji obiektu [16]. Dodatkowo w optymalizacji stochastycznej przyjmowane rozkłady często są aproksymacją wyników obserwacji, co oznacza, że przyjęty rozkład prawdopodobieństwa sam w sobie opisuje pewne zjawisko nieprecyzyjnie. Co więcej, obliczenie wpływu nowej wartości niepewności na wartość zmiennej decyzyjnej w optymalizacji stochastycznej jest niełatwe [6].

Trzecie założenie podejścia stochastycznego w zastosowaniu do rzeczywistych zjawisk jest dość kontrowersyjne. Zgodnie z jego założeniem decydenci procesu decyzyjnego akceptują z pewnym poziomem prawdopodobieństwa, że ograniczenia modelu matematycznego opisującego zjawisko zostaną zachowane. Nawiązując do zagadnienia marszrutyzacji pojazdów, planista transportu przy tworzeniu harmonogramu rozwożenia towarów, musiałby np. akceptować z 95% pewnością, że dany towar zostanie dostarczony we właściwych ramach czasowych do klienta. Z punktu widzenia firmy transportowej, w najgorszym przypadku mogłoby to oznaczać 95% jakość obsługi, wyrażoną poprzez zdążenia na czas przez kuriera. Zwiększenie poziomu prawdopodobieństwa prowadziłoby do uzyskania rozwiązania mało odpornego na niepewność danych modelu oraz do zmierzania rozwiązania stochastycznego do rozwiązania deterministycznego.

Drugim typem podejścia uwzględniającej niepewność danych modelu jest podejście odporne. Wywodzi się ona z automatyki, a dokładniej z teorii sterowania odpornego (ang. Robust Control). W procesie decyzyjnym, w którym podjęto próbę rozwiązania niepewnego modelu, należy przyjąć następujące paradygmaty [8][14]:

1. Wszystkie zmienne problemu decyzyjnego są decyzjami typu "tu i teraz" (ang. here and now variables) - wartość tych zmiennych w drodze optymalizacji musi być określona przed realizacją danych niepewnych,
2. Zbiór niepewności danych modelu jest znany np. zbiór ograniczony,
3. Ograniczenia modelu odpornego są ograniczeniami silnymi, tzn. decydent procesu decyzyjnego nie będzie akceptować jakiegokolwiek niezachowania ograniczeń modelu,

Powyższe paradygmaty są podstawowymi założeniami klasycznej optymalizacji odpornej. Pierwsze założenie wprost definiuje "uodpornienie na niepewność danych". Drugi warunek zakłada, że niepewne dane modelu są opisane przy pomocy zbiorów niepewności (ang. Uncertainty Sets). Inaczej niż w optymalizacji stochastycznej, gdzie zakłada się, że dane można opisać przy pomocy rozkładów prawdopodobieństwa. W optymalizacji odpornej nie zakłada się znajomości rozkładu prawdopodobieństwa, przyjmuje się, zgodnie z paradygmatem 2, że rzeczywisty rozkład zmienności danych zawiera się w znanym zbiorze niepewności (ang. known uncertainty support). Zbiór niepewności, w prostych formach, może być definiowany, poprzez zakres zmienności danych niepewnych, lub w zaawansowanych formach poprzez wartość oczekiwaną, dewiację, czy też kowariancję danych modelu [9][16][17].

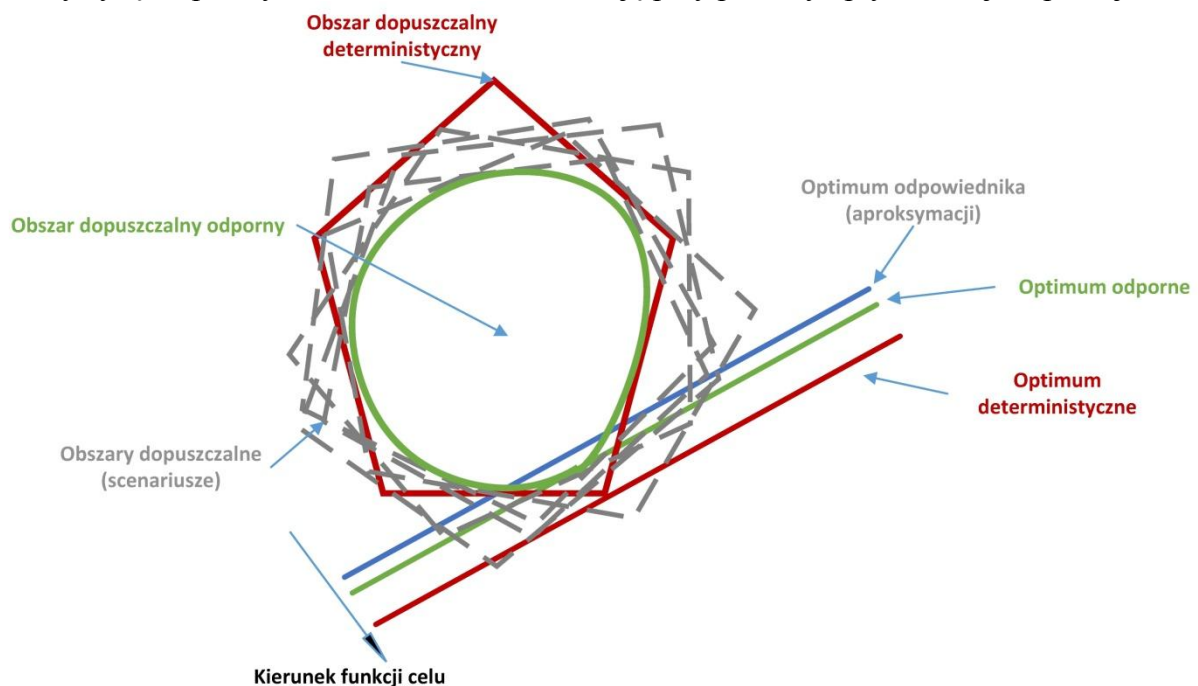
W obu typach optymalizacji: stochastycznej i odpornej, założenia mają swoje wady i zalety. Jeśli jest znany dokładny rozkład prawdopodobieństwa danych modelu, to rozwiązanie uzyskane z optymalizacji odpornej może być bardziej i niepotrzebnie konserwatywne. Jeśli z kolei rzeczywisty rozkład prawdopodobieństwa danych będzie inny od założonego, rozwiązanie stochastyczne może dać rezultaty obciążone dużym błędem - zrealizowana rzeczywista niepewność może okazać się większa

² Dostępność obliczeniowa (algorytmiczna) w teorii optymalizacji oznacza, że istnieje algorytm rozwiązujący dany problem optymalizacji w najgorszym wypadku w wielomianowym czasie obliczeń zależnym od wielkości problemu (problem P). Analogicznie dany problem jest "Nie dostępny obliczeniowo", jeżeli czas uzyskania rozwiązania nie zostanie uzyskany w czasie wielomianowym - problem NP.

niż wynikało to z założonego rozkładu. Uzyskane w ten sposób rozwiązanie może nie być odpowiednio uodpornione na wahania w wartościach danych, czego konsekwencją może być poniesienie dodatkowych kosztów w trakcie realizacji. Na przykładzie problematyki VRP można to zobrazować, jako sytuację, gdzie podczas realizacji trasy, pojazd natrafia na zator uliczny, przez co czas przejazdu się wydłuża. Jeśli przyjęty rozkład prawdopodobieństwa nie zakłada taki nieoczekiwanych wahań, może się okazać, że wyznaczona trasa jest nie optymalna, co może wygenerować dodatkowe koszty, w postaci wydłużonego czasu pracy kierowcy lub opóźnień obsługi klienta.

Ostatnie założenie podejścia odpornego przeciwnie, niż w optymalizacji stochastycznej, nie pozwala na to, aby którekolwiek z ograniczeń modelu matematycznego zostało niezachowane. Oznacza to, że uzyskane optymalne odporne rozwiązanie będzie dopuszczalne dla wszystkich możliwych scenariuszy zbioru niepewności, a celem optymalizacji jest wybór scenariusza o najmniejszym koszcie (w przypadku minimalizacji problemu). Założenie to prowadzi do poszukiwania rozwiązania najlepszego z najgorszych (ang. worst-case-oriented), co jest często wskazywane w literaturze, jako wada tego podejścia [12][16][33]. Optymalizacja zorientowana na wybór najlepszego z najgorszych, tzw. min-max, może prowadzić do nad-konserwatyźmu rozwiązania (ang. over-conservatism). Jednakże ta niedogodność może być rozwiązywana poprzez zastosowanie odpornych odpowiedników niepewnego modelu (ang. robust counterpart) [9][10][16][17]. Jedną z takich metod, radzenia sobie z nad konserwatyźmem jest przyjęcie, że zmienne decyzyjne są afinicznie zależne od zmiennych nieokreślonych.

W celu łatwiejszego wyobrażenia powyższych rozważań, na rysunku 1, przedstawiono pogładową charakterystykę niepewnych modeli oraz ich realizację przy pomocy optymalizacji odpornej.



Rys. 1. Poglądowy schemat idei poszukiwania rozwiązania w optymalizacji odpornej [14].

Obszar dopuszczalny problemu nominalnego (deterministycznego) jest większy niż obszar dopuszczalny problemu uwzględniającego niepewność danych (obszar dopuszczalny odporny). Wynika to z paradygmatów optymalizacji odpornej, które zakładają, że optymalne odporne rozwiązanie musi być dopuszczalne dla wszystkich scenariuszy zbioru niepewności. Konsekwencją takiego założenia jest ponoszenie dodatkowych kosztów związanych z uodpornieniem rozwiązania na zmienność danych. Koszt ten w literaturze przedmiotu został zdefiniowany, jako "cena uodpornienia" (ang. Price of Robustness) [9]. W przypadku minimalizacji problemu wartość funkcji celu dla nominalnego problemu będzie mniejsza niż wartość funkcji celu problemu odpornego (rysunek 1). Jak

już wspomniano powyżej, odporny model matematyczny rzeczywistych problemów, często może być formalnie zapisany w sposób nieefektywny lub wręcz nie możliwy do rozwiązania. W celu uniknięcia takiej sytuacji, metodologia optymalizacji odpornej zakłada tworzenie odpornych odpowiedników modelu lub (i dodatkowo) zastosowanie aproksymacji odpornego odpowiednika. W związku z tym, że finalny model problemu jest poddany takim procesom, optymalne rozwiązanie tak sformułowanego modelu będzie obarczone większą ceną uodpornienia.

Przedstawiona krótka charakterystyka dwóch metod radzenia sobie z danymi niepewnymi w modelowaniu matematycznym wskazuje na wady i zalety obu. Wybór odpowiedniej metody powinien uwzględniać charakterystykę opisywanego obiektu bądź systemu. W niniejszej artykule obiektem badań jest system dystrybucji towarów w systemie transportowym miasta. Niepewność parametrów tego obiektu jest trudna do zbadania i opisanie przy pomocy konkretnego wzoru matematycznego, jak również pożądanym jest, aby wyznaczone założenia modelu matematycznego były spełnione w 100%, a nie z pewną dozą prawdopodobieństwa. Wobec czego wydaje się być zasadnym stosowanie metodologii optymalizacji odpornej w odniesieniu do problematyki wyznaczania tras pojazdom w warunkach miejskich.

3. PRZEGLĄD DOTYCHCZASOWYCH OSIĄGNIĘĆ

Ostatnie dwie dekady pokazują, że zainteresowanie tematyką wyznaczania odpornych rozwiązań dla problemów wyznaczania tras pojazdom (ang. Robust Vehicle Routing Problem - dalej R-VRP) na świecie rośnie i z roku na rok przybywa prac naukowych, w których rozważane jest niniejsze zagadnienie. Jak wynika z analizy bazy Web of Science liczba publikacji, które zawierają w swoich tytułach, abstraktach lub słowach kluczowych zwrot "robust vehicle routing problem" wynosi 91 [24]. Można zauważyć tendencję wzrostową w ilości tworzonych prac na jednostkę jednego roku - w 2013 roku powstało 12 prac, gdzie w drugiej połowie lat 90-tych średnio powstała 1 praca badawcza rocznie. Jednakże, należy podkreślić, że tylko część z wyszukanych prac odnosi się do optymalizacji odpornej w zastosowaniu do problemów marszrutyzacji pojazdów. Spora część wyszukanych prac zawiera słowo "robust", jednakże odporność rozwiązania nie została uzyskana przez wykorzystanie optymalizacji odpornej [5][20][21][22][23][29]. Oznacza to, że zaproponowany model lub metodologia sama w sobie nie wykorzystuje założeń optymalizacji odpornej, a tylko uzyskane rozwiązanie posiada cechy uodpornienia na zmienność danych modelu. Takie podejście sprowadza się bardziej do analizy wrażliwości rozwiązania, niż celowego uzyskania odpornego rozwiązania na niepewność danych modelu.

Niepewność czasów przejazdów na odcinkach drogowych w problematyce VRP często jest uwzględniana poprzez dwa podejścia: stochastyczne oraz poprzez optymalizację odporną. Pierwsze podejście zakłada, że niepewność czasów przejazdu w sieci drogowej może być opisana przez z góry znany rozkład prawdopodobieństwa [11][15][25]. Jednakże, jak już wspomniano o tym powyżej, założenie to w wielu sytuacjach rzeczywistych jest niepoprawne lub jest bardzo trudno opisać właściwe przybliżenie niepewności danych poprzez rozkład prawdopodobieństwa. W związku z tym, że dalsze rozważania nawiązują tylko do optymalizacji odpornej, dalszy przegląd literatury ograniczy się do tego założenia oraz do założenia, że niepewność występuje w czasach przejazdu³. Liczba prac dotycząca tej tematyki jest niewielka i zgodnie ze stanem wiedzy autora większość z nich została omówiona poniżej.

Jedną z pierwszych prac dedykowaną odpornym modelom problematyki VRP jest artykuł [31], w którym przedstawiono matematyczny model problemu marszrutyzacji z ograniczeniem pojemnościowym pojazdów (ang. Capacitated VRP - dalej CVRP). Odporny model problemu został rozwiązany przy pomocy teorii prymalno - dualnej, dzięki czemu uzyskano model odpowiednika oryginalnego problemu w postaci programowania całkowitoliczbowego mieszanego. W analizach autorzy wykorzystali nierzeczywiste przykłady testowe - popularne przykłady testowe Solomon'a [26], które zostały zmodyfikowane na własne potrzeby. W pracy podjęto próby stworzenia

³ W literaturze często można również znaleźć prace o problematyce VRP, które odnoszą się do niepewności wielkości popytu klientów systemu dystrybucji, niepewności okien czasowych klientów, czy też czasów trwania obsługi klientów [34].

rzeczywistych warunków ruchowych, m.in. dotyczących czasów podróży na poszczególnych odcinkach sieci drogowej, jednak wartości te zostały uzyskane losowo przez przyjęcie bliżej nieokreślonych założeń. Dodatkowo w modelu matematycznym założono nierzeczywisty graf połączeń pomiędzy klientami - każdy klient jest połączony bezpośrednio z pozostałymi klientami, czyli zastosowanie modelu w rzeczywistych problemach może być trudne lub wręcz nie możliwe do wykonania.

W artykule [28] również przedstawiono problematykę odpornego modelu CVRP. Założenie modelu odnoszące się do niepewnych czasów przejazdów, sformułowano, jako maksymalną możliwą wartość czasu przejazdu na poszczególnych odcinkach, co może prowadzić, że uzyskane rozwiązanie będzie ponad-konserwatywne (ang. over-conservative solution). Rozwiązanie takie może prowadzić do ponoszenia dużo większych kosztów związanych z obsługą danego obszaru miejskiego, poprzez przyjęcie przesadnie dużych dewiacji w czasach przejazdu.

Aspekt czasów obsługi klientów realizowanych przez okna czasowe jest istotnym elementem dzisiejszej oferty usług transportowych. Również ta kwestia została podjęta w badaniach nad wyznaczaniem odpornych tras pojazdom [4]. Do uwzględnienia niepewności danych wykorzystano metodologię dwuetapowej optymalizacji odpornej (ang. Two Stage Robust Optimization). Podejście to zakłada, że część zmiennych niepewnych może dostosowywać swoje wartości do realizacji niepewności danych. Zmienne te są tworzone przy pomocy funkcji afinicznych (ang. Affine Decision Rules), czyli wartość zmiennej niepewnej zależy liniowo od realizacji zbioru danych niepewnych. Jednakże w problemach gdzie nie są uwzględniane koszty, jako funkcja czasu, podejście to sprowadza się to klasycznej optymalizacji odpornej (dowód na analogiczne twierdzenie jest zawarte w [27]). W przytoczonym artykule autorzy rozważają problem statyczny dla wyznaczania tras statkom morskim, więc zgodnie z założeniami optymalizacji odpornej [6] oraz charakterystyką modeli matematycznych VRP, ilość zmiennych niepewnych dla każdego połączenia w analizowanej sieci wynosi 1. Użycie dwuetapowej optymalizacji odpornej nie miało, więc większego uzasadnienia (analizując problem statyczny i założenia zastosowanej optymalizacji). Dodatkowo, jak już wspomniano problem dotyczył transportu morskiego, a więc przeniesienie charakterystyki połączeń pomiędzy punktami w sieci morskiej, jest nie możliwe na grunt układu sieci drogowej miasta.

W pracy [30] został zaprezentowany po raz pierwszy problem zaplanowania tras pojazdom w celu obsługi klientów z oknami czasowymi, którzy charakteryzują się popytem lub podażą na towary, gdzie funkcja celu jest połączeniem minimalizacji sześciu pod-kryteriów: konsumpcji paliwa, kosztu emisji CO₂, kosztu czasu operacyjnego pojazdu, kosztu czasu pracy kierowcy oraz kosztu zbyt wczesnego/zbyt późnego rozpoczęcia obsługi klienta. Niepewność danych modelu została wprowadzona w czterech aspektach: niepewność czasów przejazdów, niepewność czasu trwania obsługi, niepewność konsumpcji paliwa oraz niepewność wielkości emisji CO₂. Niestety w przytoczonej pracy nie przedstawiono szczegółów założeń dla stworzenia przykładów obliczeniowych, czego konsekwencją jest niemożliwa weryfikacja założeń modelu oraz ewentualna porównywalność z innymi rozwiązaniami. Kwestia incydencji połączeń w sieci również została uproszczona do pełnej macierzy połączeń (tzw. każdy z każdym), co czyni tę pracę czysto teoretyczną.

Specyfikę rzeczywistej sieci drogowej, szczególnie sieci drogowej miasta, można zrealizować w modelowaniu matematycznym przez połączenie dwóch problemów optymalizacyjnych: odpornego modelu problemu najkrótszej ścieżki (ang. Robust Shortest Path Problem) i problemu VRP. Podejście to zostało zaprezentowane w [13], gdzie rozważano problem wyznaczania tras z oknami czasowymi w aspekcie czasu (ang. Time-Dependent Vehicle Routing Problem with Time Windows). Do rozwiązania takiego modelu została wykorzystana heurystyka systemów mrówkowych (ang. Multi Ants Colony Systems). Realizacja modeli VRP na rzeczywistych sieciach drogowych jest nie możliwa w bezpośredni sposób. Powodem tego są standardowe ograniczenia modelu VRP, które zakładają, że dany odcinek drogi w realizacji tras pojazdów może być wykorzystany, co najwyżej przez jeden pojazd. Problem ten został rozwiązany poprzez połączenie problemu VRP z odpornym modelem problemu najkrótszej ścieżki. Model najkrótszej ścieżki został oparty o prace [19], w której zakłada się że prędkość na poszczególnych odcinkach sieci drogowej przyjmuje wartości z pewnego znanego

przedziału. Przedział ten tworzy zbiór niepewności dla wartości prędkości, a celem zaprezentowanego modelu jest odnalezienie ścieżki pomiędzy parą punktów w sieci, która ma najmniejszą dewiację od referencyjnej najkrótszej ścieżki. Odporny model najkrótszej ścieżki został zaadaptowany do dynamicznych czasów przejazdów, które zmieniają się z zależności od jednostki czasu - wykorzystano to do obliczenia wszystkich możliwych kosztów pomiędzy wszystkimi parami klientów. Na tak przygotowanych danych wykonano optymalizację przebiegu tras pojazdów zgodnie z założonym modelem VRP. Przedstawiona metodologia jest interesującym podejściem do wyznaczania tras pojazdom w rzeczywistych problemach transportowych. Jednakże przyjęta aproksymacja, jaką jest wcześniejsze obliczenie kosztów pomiędzy parami klientów, jest w tym wypadku niewystarczająco bliska rzeczywistości. Zaproponowany sposób wyznaczania odpornej najkrótszej ścieżki jest nastawiony tylko i wyłącznie na minimalizację czasu przejazdu. W modelu nie jest brana pod uwagę jakość obsługi klienta, która może być wyrażona poprzez wcześniejszy lub późniejszy przyjazd pojazdu do klienta. W rzeczywistości kurier może wcześniej przyjechać do klienta i na niego oczekiwać, jak również może przyjechać z niewielki opóźnieniem. Będzie to obarczone kosztami związanymi z obniżeniem jakości usług transportowych, jednak w rzeczywistości realizacja dostarczenia towaru po oczekiwanym czasie jest możliwa. Dodatkowo pominięty jest również aspekt pracy przewozowej pojazdów, która często jest wyrażana poprzez pokonany dystans przez pojazdy. Kryterium to nie zawsze idzie w parze z czasem operacyjnym pojazdu, a jest ono ważne z punktu widzenia przedsiębiorstwa transportowego.

Podobne podejście do zastosowania problematyki R-VRP na rzeczywistych sieciach drogowych zaprezentowano w pracach [3][18]. W pierwszej rozważano problem jednoczesnego rozwożenia i zbierania towarów (ang. Pickup and Delivery VRP), dzięki czemu można było uwzględnić przepływy rewersyjne w systemie dystrybucji miasta. W drugiej przytoczonej pracy rozważano problem VRP z oknami czasowymi u klientów. Wspólnym elementem obu prac jest propozycja integracji odpornej problemu najkrótszej ścieżki z problemami klasy VRP, stosując klasyczną optymalizację odporną. Optymalizacja ta charakteryzuje się wprowadzeniem do modelu matematycznego parametru kontrolowania poziomu konserwatywności rozwiązania. Zaletą takiego podejścia jest możliwość uniknięcia otrzymania rozwiązania ponad konserwatywnego, a więc nazbyt pesymistycznego. W artykule [18], podobnie jak w powyższych pracach, założono że okna czasowe u klientów są stałe, co jak wspomniano, nie do końca odpowiada rzeczywistości.

Podsumowując powyższą analizę, poruszana tematyka jest nadal niszowym obszarem badań, który w ostatnich latach zaczyna się cieszyć, co raz to większą popularnością wśród naukowców na całym świecie. W większości dotychczasowych prac wskazywano zalety stosowania optymalizacji odpornej w problematyce VRP na przykładzie przypadków testowych (nierzeczywistych). Brakuje przejrzystych badań i analiz dotyczących przypadków rzeczywistych. W celach weryfikacji poprawności modeli oraz łatwiejszej porównywalności, dane używane w analizach powinny być łatwo odtwarzalne. Często nie do końca jest klarowne, jakie jest źródło danych, czy są to dane losowo wygenerowane czy rzeczywiste z pomiaru. Dodatkowo głównym kryterium optymalizacji był całkowity czas pracy pojazdów, pomijając inne ważne kryteria tj. praca przewozowa (z punktu widzenia firmy transportowej), czy jakość obsługi klientów (z punktu widzenia firmy transportowej i klientów).

4. PODSUMOWANIE

Zastosowanie teorii optymalizacji odpornej w problematyce VRP ma na celu wprowadzenie istotnej własności rzeczywistych procesów transportowych, jaką jest niepewność oraz nieokreśloność zjawisk. Jednakże dotychczasowe prace pomijają szereg istotnych rzeczywistych aspektów tegoż procesu, co powodują, że zaproponowane modele są teoretyczne, a sposoby podejść mogą się nie dać zaimplementować w rzeczywistości. Jednakże wspólnym mianownikiem wszystkich przytoczonych badań jest fakt, że są to jedne z pierwszych prób podejmowania tej tematyki w problemach VRP. Dalsze kierunki badań nad tą tematyką powinny odbywać się dwutorowo: teoretycznie oraz praktycznie. Teoretyczny kierunek badań powinien obejmować próby rozwoju metod

optymalizacyjnych, które dawałyby rozwiązanie dobrej jakości w rozsądnym czasie obliczeniowym. Badania teoretyczne powinny również obejmować próbę bliższego opisanie rzeczywistego procesu dostarczania towarów do klientów.

Praktyczny kierunek badań powinien obejmować dokładniejsze zbadanie wpływu niepewności zjawisk drogowych na parametry ruchu drogowego, np. jak wpływają incydenty drogowe lub warunki atmosferyczne na czas przejazdu odcinków sieci drogowej. Również informacja o zmienności ruchu na poszczególnych odcinkach oraz pomiar parametrów ruchu będzie istotnym elementem dalszych badań. Zgodnie z głównymi paradygmatami teorii optymalizacji odpornej, opis niepewności danych dokonuje się przez zbiory niepewności. Właściwe opisanie tych zbiorów jest kluczowe do poprawnego opisu rzeczywistości, wobec czego dalszy rozwój rozważanej tematyki będzie wymagał pozyskania wspomnianych informacji.

Streszczenie

Niepewność zjawisk oraz procesów występujących w rzeczywistym systemie transportowym miasta jest powszechna i naturalna. Niepewność występowania tych elementów istotnie wpływa na sposób i jakość planowania transportu towarowego w mieście. Czynniki behawioralne użytkowników, warunki pogodowe, występowanie incydentów drogowych, błąd metody pomiaru, czy też metody prognozy, to jedne z wielu czynników powodujących, że estymowane czasy przejazdu mogą odbiegać od rzeczywistych wartości. Planowanie tras pojazdom o wartości danych odbiegających od rzeczywistych mogą generować zbędne koszty dla firm transportowych oraz negatywnie wpływać na środowisko naturalne. W ostatniej dekadzie można zauważyć, w światowych badaniach, powstanie nowego trendu w badaniach nad problematyką wyznaczania tras pojazdom, który zakłada, że dane mogą być niepewne. Rozwiązywanie takich problemów wykonywane jest przy pomocy optymalizacji odpornej. W artykule przedstawiono ogólną charakterystykę optymalizacji odpornej, jej porównanie z programowaniem stochastycznym, dotychczasowy stan badań aplikacyjnego zastosowania tej metodologii w problematyce marszrutyzacji oraz dalsze kierunki badań.

Słowa kluczowe: optymalizacja odporna, problem wyznaczania tras pojazdom

Application of robust optimization in vehicle routing problems - characteristics and research directions

Abstract

An uncertainty of phenomena and processes occurring in the real urban transportation system is common and natural. The uncertainty of these elements has a significant impact on the manner and quality of freight transportation planning in the cities. The user behavioral factors, weather conditions, traffic incidents, error of measurement methods or methods of predictions are small number of factors which make the estimated travel times may differ from the actual values. Route planning based improper data may lead to generate unnecessary costs for transportation companies and negatively affect the environment. In the last decade it can be found in the world's researches, the emergence of a new trend in the study of robust vehicle routing problems. Solving such problems is performed using robust optimization. The paper presents the general characteristics of the robust optimization, its comparison with the stochastic programming, the current state of research on the application into vehicle routing problems and it is shows further directions of research.

Keywords: robust optimization, vehicle routing problem

BIBLIOGRAFIA

1. Adamski A., Inteligentne systemy transportowe: sterowanie, nadzór i zarządzanie. Kraków: Wydawnictwo AGH, 2003.
2. Adamski A., Kubek D., HITS: Advanced City Logistics Systems. [aut. książki] T. Marek, i inni. Human Factor of s Global Society: a System of Systems Perspective. brak miejsca : CRC Press, 2014,
3. Adamski A., Kubek D., VRP-R: Robust routing problems solutions based on the HILS platform. Logistyka. 2014, nr 6.
4. Agra A., i inni., The robust vehicle routing problem with time windows. Computers & Operations Research. 2013, Tom 40(3),

5. Bent R., Van Hentenryck P., A two-stage hybrid local search for the vehicle routing problem with time windows. *Transportation Science*. 2004, Tom 38(4),
6. Ben-Tal A., El Ghaoui L., Nemirovski A., *Robust optimization*. New Jersey: Princeton University Press, 2009.
7. Ben-Tal A., Nemirovski A., Robust solutions of Linear Programming problems contaminated with uncertain data. *Mathematical Programming*. 2008, Tom 88(3),
8. Bertsimas D., Brown D.B., Caramanis C., *Theory and Applications of Robust Optimization*. SIAM Review. 2008, Tom 53(3),
9. Bertsimas D., Sim M., Price of Robustness. *Operations Research*. 2004, Tom 54(1)
10. Bertsimas D., Sim M., Robust discrete optimization and network flows. *Mathematical Programming*. 2003, Tom 98,
11. Bianchi L., i inni., A survey on metaheuristics for stochastic combinatorial optimization. *Natural Computing*. 2009, Tom 8(2),
12. Chen X., Sim M., Sun P., A Robust Optimization Perspective on Stochastic Programming. *Operations Research*. 2007, Tom 55(6),
13. Donati A.V., i inni., Time dependent vehicle routing problem with a multi ant colony system. *European Journal of Operational Research*. 2008, 185,
14. El Ghaoui L., Uniwersytet w Berkeley. *Robust Optimization and Applications*. [Online] [Zacytowano: 17 styczeń 2015.] <http://www.eecs.berkeley.edu/~elghaoui/Talks/talkIMA2003b.pdf>.
15. Fleury G., Lacomme P., Prins C., Evolutionary Algorithms for Stochastic Arc Routing Problems. *Applications of Evolutionary Computing*. 2004, Tom 3005,
16. Goh J., Sim M., Distributionally Robust Optimization and Its Tractable Approximations. *Operations Research*. 2010, Tom 58(4),
17. Goh J., Sim M., Robust Optimization Made Easy with ROME. *Operations Research*. 2011, Tom 59(4),
18. Kubek D., Integration of robust shortest path with pickup and delivery vehicle routing problem. *Proceedings of the Second International Conference on Traffic and Transport Engineering ICTTE*. 2014.
19. Montemanni R., Gambardella L.M., Donati A.V., A branch and bound algorithm for the robust shortest path problem with interval data. *Operations Research Letters*. 2004, Tom 32,
20. Osman I.H., Wassan N.A., A reactive tabu search meta-heuristic for the vehicle routing problem with back-hauls. *JOURNAL OF SCHEDULING*. 2002, Tom 5(4),
21. Pisinger D., Ropke S., A general heuristic for vehicle routing problems. *Computers & Operations Research*. 2007, Tom 34(8),
22. Ropke S., Pisinger D., An adaptive large neighborhood search heuristic for the pickup and delivery problem with time windows. *Transportation Science*. 2006, Tom 40(4),
23. Russell R.A., Chiang W.C., Scatter search for the vehicle routing problem with time windows. *European Journal Of Operational Research*. 2005, Tom 169(2),
24. Science. Web of Science.[Online] [Zacytowano: 30 grudzień 2014.] <https://webofknowledge.com/>
25. Shapiro A., Dentcheva S., Ruszczyński A., *Lectures on stochastic programming: modeling and theory*: SIAM-Society for Industrial and Applied Mathematics, 2009,
26. Solomon M.M., Algorithms for the vehicle routing and scheduling problems with time window constraints. *Operatoin Research*. 1987, Tom 35(2),
27. Solyali O., Cordeau J.F., Laporte G., Robust Inventory Routing Under Demand Uncertainty. *Transportation Science*. 2011, Tom 46(3),
28. Sungur I., Ordenez F., Dessouky M., A robust optimization approach for the capacitated vehicle routing. *IIE Transactions*. 2008, Tom 40,
29. Taillard ED., A heuristic column generation method for the heterogeneous fleet VRP. *RAIRO-Recherche Operationnelle-Operations Research*. 1999, Tom 33(1),
30. Tajik N., i inni., A robust optimization approach for pollution routing problem with pickup and delivery under uncertainty. *Journal of Manufacturing Systems*. 2014, Tom 33(2),

31. Tan K. C., Cheong C.Y., Goh C.K., Solving multiobjective vehicle routing problem with stochastic demand via evolutionary computation. *European Journal Of Operational Research*. 2007, Tom 177, 2,
32. Tarantilis C.D., Kiranoudis C.T., Vassiliadis, V.S., A threshold accepting metaheuristic for the heterogeneous fixed fleet vehicle routing problem. *European Journal Of Operational Research*. 2004, Tom 152(1),
33. Thiele A., Robust stochastic programming with uncertain probabilities. *IMA J Management Math*. 2008, Tom 19, 3,
34. Verderame P.M., i inni, Planning and Scheduling under Uncertainty: A Review Across Multiple Sectors. *Ind. Eng. Chem. Res.* 2010, Tom 49(9),