
POLITECHNIKA KRAKOWSKA IM. TADEUSZA KOŚCIUSZKI

WYDZIAŁ INŻYNIERII LĄDOWEJ

INSTYTUT ZARZĄDZANIA W BUDOWNICTWIE I TRANSPORCIE

ZAKŁAD TRANSPORTU

PRACA DOKTORSKA

***OPTIMALIZACJA TYPU "ROBUST" TRAS PRZEWOZU
ŁADUNKÓW NA OBSZARACH MIEJSKICH***

AUTOR: MGR INŻ. DANIEL KUBEK

PROMOTOR: PROF. DR HAB. INŻ. ANDRZEJ ADAMSKI

KRAKÓW, CZERWIEC 2016



*Pracę tę dedykuje
żonie Lidii, córce Alicji oraz synowi Krzysiówi*

Spis treści

Streszczenie	6
Summary	7
1 Wprowadzenie	8
1.1 Tło rozważań	8
1.2 Sformułowanie problemu badawczego, celu, tez badawczych oraz zakresu pracy	11
1.3 Wykaz najważniejszych oznaczeń.....	14
2 Dystrybucja towarów na obszarach miejskich	20
2.1 Charakterystyka miejskiej dystrybucji towarów.....	20
2.1.1 Wpływ przewozu towarów w miastach na system logistyczny miasta	24
2.1.2 Zagadnienie wyznaczania tras pojazdów jako element zarządzania	33
2.2 Problematyka wyznaczania tras pojazdów	35
2.3 Problem wyznaczania tras pojazdów w ujęciu systemowym	41
2.4 Wnioski z rozdziału nr 2.....	46
3 Problem optymalizacji tras pojazdów w warunkach niepewności na obszarach miejskich...	48
3.1 Źródła niepewności danych o parametrach miejskiego ruchu drogowego w modelach optymalizacyjnych.....	48
3.2 Charakterystyka teorii optymalizacji odpornej na wahania parametrów modelu matematycznego	50
3.3 Model niepewności danych w programowaniu liniowym	55
3.3.1 Programowanie liniowe typu robust - charakterystyka ogólna	55
3.3.2 Programowanie całkowitoliczbowe odporne na wahania parametrów modelu matematycznego	60
3.4 Przegląd wybranych modeli uwzględniających niepewność danych w problemach wyznaczania tras pojazdów	62
3.4.1 Polskie badania w zakresie modelowania niepewności danych	62
3.4.2 Zagraniczne badania w zakresie modelowania niepewności danych	63
3.5 Wnioski z rozdziału nr 3.....	66
4 Model optymalizacyjny problemu wyznaczania tras pojazdów w obszarach miejskich z uwzględnieniem niepewności danych	69
4.1 Deterministyczny problem wyznaczania tras pojazdów uwzględniający elastyczne okna czasowe oraz przepływy rewersyjne towarów z danymi zależnymi od czasu - TD-VRP-STW	70
4.1.1 Specyfika i założenia ogólne problemu TD-VRP-STW	70
4.1.2 Czterokryterialne sformułowanie problemu TD-VRP-STW	72
4.1.3 Pięciokryterialne sformułowanie problemu TD-VRP-STW.....	79
4.1.4 Normalizacja funkcji kryterialnej problemu TD-VRP-STW.....	80

4.1.5 Charakterystyka oraz użyteczność modeli dla problemu TD-VRP-STW	81
4.2 Metodyka rozwiązywania zagadnień wyznaczania tras pojazdów z parametrami niepewnymi	84
4.2.1 Niepewność wartości czasu obsługi w problemie TD-VRP-STW	84
4.2.2 Niepewność wartości czasu przejazdu przez odcinki drogowe w problemie TD-VRP-STW	85
4.3 Dwukryterialny problem optymalizacyjny najkrótszej ścieżki.....	90
4.3.1 Wersja deterministyczna problemu najkrótszej ścieżki - SPP	90
4.3.2 Wersja odporna na wahania parametrów problemu najkrótszej ścieżki - R-SPP.....	92
4.4 Deterministyczny problem optymalizacyjny wyznaczania tras pojazdów uwzględniający elastyczne okna czasowe oraz przepływy rewersyjne towarów - VRP-STW	94
4.5 Przepływ danych w metodyce optymalizacji zagadnień wyznaczania tras pojazdów.....	99
4.6 Wnioski z rozdziału nr 4.....	102
5 Symulacje komputerowe i analiza proponowanych modeli matematycznych	103
5.1 Specyfikacja wybranej sieci drogowej	103
5.1.1 Wybrany obszar miejski	103
5.1.2 Proces tworzenia modelu mikroskopowego	104
5.2 Charakterystyka problemu R-SPP najkrótszej ścieżki odpornej na wahania parametrów	121
5.2.1 Zbiór danych testowych.....	121
5.2.2 Użyteczność modelu.....	122
5.2.3 Wpływ parametru konserwatywności na rozwiązanie w modelu (RC_{SPP}^e).....	123
5.2.4 Wpływ wagi funkcji kryterialnej na rozwiązanie w modelu (RC_{SPP}^e).....	124
5.2.5 Pozytywne i negatywne aspekty stosowania rozwiązań modelu (RC_{SPP}^e)	125
5.3 Analiza parametrów modeli ($nVRP1$) oraz ($nVRP2$)	127
5.3.1 Wpływ wagi kryteriów na rozwiązanie modeli ($nVRP1$) oraz ($nVRP2$)	127
5.3.2 Użyteczność modeli ($nVRP1$) oraz ($nVRP2$)	131
5.4 Wniosku z rozdziału nr 5.....	136
6 Analiza metodyki integracji problemu najkrótszej ścieżki R-SPP z zagadnieniem wyznaczania tras pojazdów VRP-STW.....	137
6.1 Metoda porównywania rozwiązań.....	139
6.1.1 Parametry oceny rozwiązań.....	139
6.1.2 Schemat porównywania rozwiązań	139
6.2 Porównanie wariantu odpornościowego z wariantem deterministycznym.....	143
6.2.1 Wpływ liczebności klientów i poziomu konserwatywności na jakość rozwiązania	143
6.2.2 Wpływ typu modelu na jakość rozwiązania	153
6.2.3 Wpływ struktury okien czasowych na jakość rozwiązania	155

6.2.4 Analiza zmienności znormalizowanej wartości funkcji kryterialnej dla podejścia deterministycznego i odpornościowego	158
6.3 Porównanie wariantu odpornościowego z wariantem stochastycznym.....	161
6.3.1 Wpływ liczebności klientów i poziomu konserwatyzmu na jakość rozwiązania.....	162
6.3.2 Analiza zmienności znormalizowanej wartości funkcji kryterialnej dla podejścia stochastycznego i odpornościowego	169
6.4 Wnioski z rozdziału nr 6.....	171
7 Podsumowanie i wnioski.....	173
7.1 Spełnienie założonych celów oraz weryfikacja postawionej tezy	173
7.2 Wnioski i dyskusja wyników	175
7.3 Kierunki dalszych badań.....	177
Bibliografia	178
Spis rysunków	185
Spis tabel.....	188
Załącznik A.	189
Załącznik B.	191

STRESZCZENIE

"Uncertainty is an uncomfortable position. But certainty is an absurd one."
François-Marie Arouet de Voltaire

Zaprezentowana rozprawa doktorska dotyczy problematyki wyznaczania tras pojazdów na obszarach miejskich, która uwzględnia naturalną losowość występujących zjawisk w sieci drogowej miasta. Charakterystyka procesów transportowych występujących w dystrybucji towarów, została uzyskana przez ujęcie tych procesów przez pryzmat koncepcji logistyki miejskiej. Istotnym założeniem proponowanych modeli jest przyjęcie, że wspomniana losowość nie jest zdefiniowana jako proces stochastyczny, lecz jako niepewność. Takie rozumienie potencjalnych, a priori nieznanymi zmian w wartościach parametrów modelu umożliwia dokładniejsze opisanie nieprzewidywalnych procesów zachodzących w ruchu miejskim. Właściwe opisanie tych zjawisk jest istotne dla założenia wartości czasów przejazdów przez poszczególne odcinki w sieci drogowej miasta, co z kolei jest główną determinantą specyfikacji problemowych i jakości rozwiązania zagadnienia planowania przewozu towarów.

Głównym osiągniętym celem pracy jest zdefiniowanie matematycznego wielokryterialnego modelu zależnego od czasu dla problemu wyznaczania tras pojazdów, uwzględniającego elastyczne okna obsługi klientów oraz przepływy wsteczne towarów. Drugą oryginalną kwestią jest opracowana metoda implementacji niepewności wartości parametrów w zaproponowanym modelu, która wykorzystuje charakterystykę losowości ruchu miejskiego. Przedstawione podejście bazuje na połączeniu dwóch prostszych zagadnień: dwukryterialnego problemu najkrótszej ścieżki zależnego od czasu z niepewnymi parametrami oraz deterministycznego wielokryterialnego modelu wyznaczania tras pojazdów uwzględniającego elastyczne okna czasowe obsługi oraz wsteczne przepływy towarów. Jak pokazują analizy, połączenie obu modeli umożliwia uproszczenie poziomu złożoności obliczeniowej przy jednoczesnym uzyskaniu potencjalnych pozytywnych efektów stosowania.

Potencjalne efekty stosowania zaprezentowanej metodyki zostały otrzymane w wyniku przetestowania szeregu przykładów obliczeniowych, których struktura została utworzona w oparciu o informacje pozyskane z wywiadu z firmą transportową oraz o charakterystykę rzeczywistego ruchu drogowego wybranego obszaru Krakowa. Otrzymane rezultaty zostały porównane z dwoma popularnymi podejściami: deterministycznym oraz stochastycznym. Zestawienia dokonano poprzez ocenę jakości każdego z rozwiązań na podstawie wartości wybranych parametrów. W wyniku przeprowadzonych symulacji obliczeniowych uzyskano charakterystykę każdego z podejść, co umożliwiło wskazanie potencjalnych zysków i strat stosowania proponowanego podejścia.

SUMMARY

"Uncertainty is an uncomfortable position. But certainty is an absurd one."

François-Marie Arouet de Voltaire

The presented doctoral thesis deals with the issues of vehicle routing problem in urban areas, which takes into account the natural randomness of traffic phenomena in the urban areas. Characteristics of transport processes occurring in the goods distribution has been obtained by the concept of city logistics systems activities. An important issue of the proposed model is the assumption that random changes are not defined as stochastic processes, but as uncertainty variables. Such approach is more compatible to describe unpredictable processes in urban traffic, because it is not possible to indicate the probability distribution which could describe such changes. Appropriate defining the randomness of travel times in the road network is important issue in mathematical model specifications. It is the main determinant of the quality of obtaining solution of the freight transport planning in the city.

The main achievement in the thesis is proposition of the model for time-dependent multicriteria vehicle routing problem with simultaneous pickups and delivery and soft time windows. The second crucial issue of research is original approach to handle uncertainty of urban traffic parameters in the proposed model. The approach is based on a combination of two simplest sub-problems: bi-criteria robust shortest path problem with time-dependent features and corresponding multi-criteria vehicle routing problem with simultaneous pickups and delivery and soft time windows. As shown by the analysis, the dedicated integration of both models allows to get more computationally tractable version and simultaneously obtaining the potential positive effects of use.

The presented methodology was tested by series of experiments which structures were based on information gained from transportation company with the assumption of real traffic characteristics for selected area of Cracow. According to the tests the potential effects of use was obtained in comparing with popular approaches: deterministic and stochastic. Statements were made by evaluating the quality of each solution based on the value of selected parameters. As a result of the numerical simulations the characteristics of each approach was obtained, which enabled to identify a potential benefits and losses of applying the proposed approach.

1 WPROWADZENIE

1.1 TŁO ROZWAŻAŃ

Funkcjonowanie współczesnych miast jest nierozzerwalnie związane z działaniem transportu. Transport w systemie miejskim jest głównym motorem rozwoju miasta. Od jego efektywności zależy sukces miast, który może być wyrażony poprzez aspekt: zrównoważonego, ekonomicznego i ekologicznego rozwoju, jakości życia mieszkańców, dostępności i atrakcyjności transportu, a nawet wizerunku turystycznego przestrzeni miejskiej. System transportowy miasta można podzielić na trzy główne komponenty: podsystem transportu zbiorowego, podsystem transportu indywidualnego oraz podsystem transportu towarów. Na podstawie przeglądu literatury można zauważyć, że w ostatnich dekadach głównymi obiektami badań naukowych były pierwsze dwa podsystemy - transport zbiorowy (publiczny) oraz indywidualny. Jednakże dynamiczny rozwój miast, postępująca urbanizacja oraz wzrost popytu na towarowe usługi transportowe powodują równie dynamiczny i często niekontrolowany rozwój transportu towarowego. Fakt ten spowodował, że w ostatnich latach wielu badaczy, organizacji międzynarodowych, jak również lokalnych władz miast zwróciło swoją uwagę na ten element systemu transportowego miasta [30, 97, 104].

Towarowy system transportowy (ang. Urban Goods Transport; Urban Freight Distribution) w mieście to ogół procesów oraz wszystkich obiektów biorących udział w przemieszczaniu towarów na obszarze miejskim. W skład towarowego systemu miejskiego wchodzi następujące elementy: sieć drogową, środki transportu towarów, przedsiębiorstwa przewoźne świadczące usługi transportowe na terenach miejskich (np. firmy kurierskie, firmy pocztowe, dostawcy towarów), odbiorcy towarów (klienci indywidualni, sklepy, biura, urzędy, przedsiębiorstwa usługowe, itp.) oraz przewożone obiekty, czyli towary. Komponentami tego podsystemu są również elementy wspólne z pozostałymi podsystemami, czyli ruch drogowy, infrastruktura drogową (znaki drogowe, sygnalizacja świetlna) oraz miejsca postojowe, na których realizowany jest rozładunek pojazdu (zatoczki rozładunkowe, miejsca parkingowe). Uczestnikami towarowego systemu transportowego miasta są: władze i zarządy miast, mieszkańcy, spedytorzy, przewoźnicy oraz producenci, sprzedawcy i handlowcy [104, 139].

Proces transportowy jest to zespół działań organizacyjnych, wykonawczych i administracyjnych, które są realizowane przez grupę wyspecjalizowanych pracowników w ściśle określonej kolejności, z użyciem środków transportowych w celu przemieszczania ładunków pomiędzy określonymi lokalizacjami. W procesie transportowym występują działania związane z przygotowaniem ładunku do przewozu, tymczasowe magazynowanie, proces przewoźowy (załadunek, przewóz, rozładunek, przeładunek towarów) oraz czynności spedycyjne [113].

Rozważanie dystrybucji towarów w miastach uwzględniające tylko i wyłącznie procesy transportowe, nie byłoby poprawne. Jest to spowodowane faktem, że przy planowaniu procesu transportowego nie uwzględnia się wpływu realizowanego przewozu (transportu) na otoczenie. Zgodnie z przytoczoną powyżej definicją, proces transportowy odnosi się tylko i wy-

łącznie do fizycznego przewozu towaru oraz do jego realizacji zgodnie z przyjętymi kryteriami (głównie z punktu widzenia przedsiębiorstwa transportowego). Rozszerzeniem takiego rozumienia procesu transportu na obszarach miejskich jest koncepcja logistyki miejskiej (ang. City Logistic). Logistyka miejska to nowa dziedzina nauki zajmująca się procesami występującymi na obszarach miejskich, związanymi głównie z procesem przemieszczania osób, towarów, informacji czy usług w kontekście systemowym miasta (szczegółowa definicja w podrozdziale 2.1). Oznacza to, że pojedyncze procesy transportu towarów są analizowane w ujęciu całościowym, czyli wraz z ich wpływem na otoczenie i pozostałych uczestników systemu miasta.

Każda realizacja transportu towarów w mieście charakteryzuje się specyficznymi problemami funkcjonowania, które są wynikiem oddziaływania pozostałych uczestników systemu. W raporcie dotyczącym transportu towarów w XXI wieku przygotowanym przez Organizację Współpracy Gospodarczej i Rozwoju (ang. Organization for Economic Co-operation and Development - dalej OECD) [104] przedstawiono problemy transportowe, które wpływały, wpływają i będą wpływać na sposób organizacji transportu w miastach. Można do nich zaliczyć problemy z: dostępnością transportową, zatłoczeniem transportowym, wpływem na środowisko, poziomem bezpieczeństwa, czy też wizerunkiem miasta w ujęciu turystycznym. Poza kwestiami dotyczącymi strony transportowej dochodzą również czynniki po stronie uczestników systemu logistycznego miasta, których wpływ jest istotnym kreatorem struktury transportu towarów (szczegóły w podrozdziale 2.1.1). Dla przykładu są to: zmiany społeczne, technologiczne, postępująca urbanizacja, czy też struktura łańcucha dostaw. Dopiero takie podejście do opisu pozornie prostego procesu, jakim jest przewóz towarów w mieście, umożliwia właściwą identyfikację problemów, jakie są przez ten proces generowane. Główne problemy realizacji transportu towarów w miastach to: brak koordynacji przepływu towarów, emisja spalin, emisja hałasu przez pojazdy, blokowanie płynności ruchu (pieszego i kołowego), zwiększanie zatłoczenia transportowego przy jednoczesnym zmniejszaniu dostępności transportowej oraz negatywne wpływanie na poziom bezpieczeństwa [29, 39, 86, 128, 148].

Ostatnie lata pokazują duże zainteresowanie aspektami poprawy efektywności dystrybucji towarów w miastach, szczególnie przez władze miast, państw a nawet odpowiednich jednostek administracji Unii Europejskiej. Przykładem takich działań są liczne projekty badawcze tj. BESTUFS [29], CIVITAS CARAVEL [39], TRAILBLAZER [148], SUGAR [128] oraz LaMilo [86]. Głównym celem tych projektów jest stworzenie nowych rozwiązań, które miałyby zmniejszać negatywny wpływ dystrybucji towarów w miastach na otoczenie. Oprócz wspomnianych projektów powstały również dokumenty utworzone przez jednostki administracyjne UE oraz Stanów Zjednoczonych, które zawierają m.in. zbiór rekomendowanych rozwiązań poprawy jakości dystrybucji towarów. Wśród tych rozwiązań problematyka wyznaczania tras pojazdów jest również wymieniana [97, 151]. Jest ona wskazywana jako rozwiązanie o potencjalnie niskim koszcie wdrożenia, dające dobre efekty w postaci zmniejszenia wpływu transportu towarów na mieszkańców, miasto oraz środowisko naturalne (szczegóły w podrozdziałach 2.1.2). Poruszone powyżej kwestie były przyczyną do sprawdzenia, jaki jest aktualny stan wiedzy i badań w obszarze zagadnień wyznaczania tras pojazdów w obszarach miejskich.

Najogólniej rzecz ujmując problem wyznaczania tras pojazdów (ang. Vehicle Routing Problem - dalej VRP) to bardzo dobrze znane zagadnienie z dziedziny badań operacyjnych, którego celem jest wskazanie optymalnych tras poruszania się pojazdów w sieci drogowej, w celu świadczenia usług transportowych klientom. Optymalne trasy mogą być rozumiane jako trasy o najmniejszym przyjętym koszcie, np. czas poruszania się pojazdu, pokonany dystans przez pojazdy, zużycie paliwa, wozokilometry, emisja spalin, itp. Niewłaściwe wyznaczenie tras pojazdów może skutkować ponoszeniem zbędnych kosztów przez firmę transportową, ale i przez otoczenie (mieszkańcy, środowisko naturalne). I na tym etapie pojawia się pierwsze pytanie: co oznacza "właściwe rozwiązanie" dla zagadnień wyznaczania tras pojazdów w mieście?

Aby odpowiedzieć na to pytanie należy przeanalizować proces dystrybucji towarów w mieście w celu identyfikacji potencjalnych problemów. Kierowca realizujący trasę przez odwiedzanie kolejnych klientów, rozwożąc im towary (lub odbierając) porusza się pojazdem w sieci drogowej, a więc jest uczestnikiem ruchu. Będąc uczestnikiem ruchu sposób jego poruszania jest uzależniony od aktualnej sytuacji ruchowej w sieci, np. jeśli występuje zator drogowy, to czas przejazdu pojazdu również wzrasta. Dłuższy czas przebywania w sieci, to automatyczny wzrost kosztów realizacji takiej trasy. Koszty te mogą wynikać z: dłuższego czasu pracy kierowcy, większego zużycia paliwa przez pojazd, a co za tym idzie większej emisji szkodliwych spalin lub wystąpienia potencjalnych incydentów drogowych, spowodowanych przez narastającą frustrację kierowcy (przede wszystkim wskutek reżimu czasowego narzuconego przez firmę transportową). Dodatkowo coraz częściej w usługach kurierskich występuje możliwość wyboru przez klienta interwału czasowego, w którym życzyłby sobie, aby usługa transportowa została wykonana. W sytuacji, gdy wystąpią opóźnienia w trakcie przejazdu przez sieć drogową miasta, istnieje duże prawdopodobieństwo, że kierowca przyjedzie do niektórych klientów opóźniony. Przy obecnym wysokim poziomie konkurencji na rynku przesyłek kurierskich może to mieć duże znaczenie dla wizerunku firmy i świadczonych przez nich jakości usług. Występowanie wspomnianych kosztów jest wynikiem realizacji otrzymanego rozwiązania problemu VRP w wysoce dynamicznym i losowym elemencie systemu transportowego miasta, jakim jest ruch drogowy. Zatem "właściwym rozwiązaniem" wydaje się być takie, którego podatność na zmienność parametrów ruchu była jak najmniejsza, przy jednoczesnym zachowaniu niskich kosztów realizacji tras. Istotnym dla problemów VRP parametrem ruchu drogowego jest czas przejazdu przez sieć drogową, którego wartości bezpośrednio wpływają na realizację tras.

W tym punkcie rozważań pojawia się kolejne pytanie: jak uwzględnić zmienność czasu przejazdu w sieci drogowej w procesie planowania tras pojazdów? Jednym ze sposobów jest odpowiednia reprezentacja danych przyjmowanych w modelach matematycznych zagadnień VRP. Z przeprowadzonego przeglądu literatury (podrozdział 2.2) wynika, że najbardziej popularny sposób reprezentacji zmiennych parametrów modelu, to podejście stochastyczne. Podejście stochastyczne zakłada, że dany parametr (tu czas przejazdu) w danym przedziale czasu jest zmienną losową, a jej zmienność jest opisana znanym rozkładem prawdopodobieństwa. Jednak biorąc pod uwagę naturalną cechę ruchu drogowego - nieprzewidywalność i nieokreśloność, powstaje wątpliwość czy opis zmienności przez znane rozkłady prawdopodobieństwa jest właściwym podejściem.

Alternatywnym sposobem opisu parametrów losowych jest podejście opisane przez teorię optymalizacji odpornej na wahania parametrów¹ (ang. Robust Optimization). Podobnie jak w podejściu stochastycznym zakłada się zmienność parametrów modelu, jednak zmienność ta nie jest opisana rozkładem, tylko poprzez zbiory niepewności (ang. Uncertainty Sets). Zbiory te w różnych formach są definiowane przez przedziały zmienności, wartość wariancji, macierz kowariancji czy też funkcje afiniczne [22]. Mając na uwadze specyfikę ruchu drogowego miasta - występowanie nieprzewidywalnych incydentów drogowych i założenia teorii optymalizacji odpornej na wahania parametrów modelu, wydaje się być zasadne wykorzystanie tego podejścia w zagadnieniach wyznaczania tras. Jednak jak wynika z dokonanego przeglądu aktualnego stanu badań zastosowanie tej teorii w problematyce VRP jest dość nowym obiektem rozważań, szczególnie w literaturze polskiej (podrozdział 3.4).

W literaturze zagranicznej można zaobserwować z roku na rok, co raz to większe zainteresowanie tą tematyką, co wpływa na kształtowanie nowych kierunków badań w tym zakresie. Szczegółowy opis dotychczasowych osiągnięć zaprezentowano w podrozdziale 3.4 jednak główny wniosek jaki można z niego przytoczyć to: w obecnych badaniach brakuje podejścia, w którym uwzględnione byłyby bardziej rzeczywiste uwarunkowania dystrybucji towarów. Między innymi są to:

1. Nieodpowiednie miejsce implementacji zmienności (nieokreśloności) parametrów modelu matematycznego,
2. Brak uwzględniania możliwości wystąpienia wcześniejszej i/lub późniejszej obsługi klienta,
3. Brak uwzględnienia przepływów rewersyjnych towarów,
4. Brak uwzględnienia wielokryterialności celu przy poszukiwaniu przestrzeni rozwiązań dopuszczalnych,
5. Brak odniesienia proponowanych nowych rozwiązań do istniejących metod.

Uwzględnienie wyżej wymienionych aspektów w problematyce wyznaczania tras pojazdów stały się celami autora pracy.

1.2 SFORMUŁOWANIE PROBLEMU BADAWCZEGO, CELU, TEZ BADAWCZYCH ORAZ ZAKRESU PRACY

Na podstawie dokonanego przeglądu literatury sformułowano problem badawczy polegający na: identyfikacji charakterystyki zagadnienia wyznaczania tras pojazdów w obszarach miejskich oraz na zastosowaniu dostępnych metodyk modelowania matematycznego do opisu problemu wyznaczania tras pojazdów w warunkach niepewności. Praca przedstawia badania teoretyczne o charakterze metodologicznym.

Głównym celem pracy doktorskiej jest stworzenie metodyki rozwiązywania praktycznie poszukiwanych zagadnień wyznaczania tras pojazdów, w której została uwzględniona niepewność czasów przejazdów w sieci drogowej miasta.

¹ W polskiej literaturze nie ma jednoznacznie funkcjonującego terminu na opis tego rodzaju metod. Inne sformułowania to: optymalizacja odporna, optymalizacja odpornościowa lub optymalizacja typu "robust". W dalszej części pracy będą one stosowane wymiennie.

Celami pośrednimi pracy są:

- 1. Sformalizowanie zapisu modelu matematycznego, który uwzględnia wielokryterialność celu poszukiwania rozwiązania dla zagadnień związanych z dystrybucją towarów w miastach,*
- 2. Wskazanie potencjalnych zysków i strat stosowania podejścia uwzględniającego zmienność parametrów modelu matematycznego.*
- 3. Opracowanie propozycji umiejscowienia zagadnień wyznaczania tras pojazdów metodami optymalizacji odpornej na wahania parametrów w nowoczesnej koncepcji inteligentnych systemów logistycznych miasta.*

Na opracowaną metodykę składają się następujące zadania badawcze:

- Przegląd literatury przedmiotu z zakresu problematyki wyznaczania tras, w której uwzględniono zmienność parametrów modelu. Określenie luki badawczej.
- Identyfikacja charakterystyki dystrybucji towarów w mieście oraz kryteriów oceny rozwiązań, na podstawie wywiadów przeprowadzonych z przedstawicielami firm transportowo - logistycznych,
- Wykonanie diagnozy aktualnego stanu wiedzy z zakresu optymalizacji odpornej na wahania parametrów modelu matematycznego w zagadnieniach trasowania pojazdów.
- Opracowanie deterministycznego modelu matematycznego, którego parametry zależą od czasu dla zagadnienia wyznaczania tras pojazdów uwzględniającego przepływy rewersyjne oraz elastyczne okna czasowe, w którym cel jest opisany pięcioma kryteriami.
- Opracowanie autorskiej metody rozwiązywania zadań optymalizacyjnych z zakresu układania tras pojazdów.
- Opracowanie modelu matematycznego o parametrach przedziałowych dla zagadnienia najkrótszej ścieżki, którego dane są opisane przy pomocy afinicznych zbiorów niepewności, a cel optymalizacji jest wyrażony dwoma kryteriami.
- Pozyskanie wiarygodnych danych empirycznych opisujących charakterystykę sieci drogowej wybranego obszaru miasta Krakowa, w celu wykonania poprawnych eksperymentów symulacyjnych,
- Przeprowadzenie eksperymentów, w których wykorzystano nowoczesne narzędzie do wykonywania symulacji mikroskopowej ruchu drogowego Aimsun, w celach pozyskania wiarygodnych danych o charakterystyce zmienności czasu przejazdu przez sieć.
- Wykonanie eksperymentów obliczeniowych przy użyciu specjalistycznych programów komputerowych tj. Matlab, zestaw narzędzi ROME oraz pakiet CPLEX, w celu weryfikacji przyjętych założeń modeli.
- Przeprowadzenie analizy wyników w odniesieniu do klasycznych podejść.
- Krytyczna ocena użyteczności proponowanej metodyki oraz wskazanie dalszych kierunków badań.

W dysertacji przyjęto następujące tezy badawcze:

Główna teza pracy:

Matematyczne modele zagadnień wyznaczania tras pojazdów uwzględniające niepewność wartości parametrów, wynikającą z niemożliwości precyzyjnego określenia przyszłych ich wartości, których charakterystyka została zdefiniowana w oparciu o teorię optymalizacji typu "robust", pozwalają na bardziej reprezentatywne opisanie procesu rozwożenia towarów w mieście.

Teza pomocnicza pracy:

Zastosowanie optymalizacji odpornej na wahania parametrów modelu w problematyce wyznaczania tras pojazdów pozwala na uzyskanie lepszej jakości i wyższej praktycznej użyteczności rozwiązań niż klasyczne podejścia.

Praca składa się z siedmiu rozdziałów. Rozdział pierwszy wprowadza problematykę rozprawy, definiuje lukę badawczą, cel badań naukowych, zadania badawcze, tezy oraz zakres pracy. Dodatkowo dla zachowania czytelności przedstawiono strukturę pracy, słownik pojęć oraz wykaz najważniejszych oznaczeń stosowanych w pracy.

W drugim rozdziale został scharakteryzowany miejski system transportu towarów, ze szczególnym zwróceniem uwagi na aspekty logistyczne procesów transportowych. Przedstawiono również rekomendacje jednostek administracyjnych Unii Europejskiej oraz Stanów Zjednoczonych dotyczących problematyki marszrutyzacji na terenach miejskich. Jako posumowanie tego rozdziału przedstawiono propozycję systemowego ujęcia problematyki wyznaczania tras przy pomocy koncepcji Inteligentnych Systemów Logistycznych.

W rozdziale trzecim scharakteryzowano problematykę wyznaczania tras, dokonano przeglądu występujących odmian oraz wskazano rodzaje danych wykorzystywanych w tych zagadnieniach. Wprowadzono podstawowe pojęcia związane z optymalizacją odporną na wahania parametrów modelu oraz przedstawiono jej charakterystykę. Zaprezentowany sposób stosowania pojęć związanych z niepewnością zjawisk, umożliwił dokonanie przeglądu literatury przedmiotu w zakresie stosowania odpornych modeli problemów wyznaczania tras pojazdów.

Rozdział czwarty jest rozdziałem teoretycznym, zawiera on część modelowania matematycznego zdefiniowanego problemu. Przedstawiono w nim charakterystykę autorskiego modelu zależnego od czasu, zagadnienia wyznaczania tras pojazdów uwzględniającego przepływy rewersyjne oraz elastyczne okna czasowe, w którym cel jest opisany pięcioma kryteriami. Kolejne rozważania to dekompozycja problemu do prostszych form, w celu umożliwienia wprowadzania niepewności danych oraz wierniejszego opisu rzeczywistego procesu dystrybucji towarów. W rozdziale tym zaproponowano dwie prostsze formy modelu matematycznego dla zagadnienia wyznaczania tras pojazdom - pierwsza zakłada minimalizację czterech celów, a druga pięciu.

W rozdziale piątym zaprezentowano wyniki symulacji komputerowych, w których dokonano analizy i weryfikacje proponowanych podejść. Została również przedstawiona charakterystyka zaproponowanych modeli oraz określona użyteczność stosowania. W celu zachowania wiarygodnych wyników, symulacje komputerowe zostały wykonane w oparciu o dane

uzyskane z symulatora ruchu drogowego, który został skalibrowany z pomiarami rzeczywistymi. Charakterystyka i opis procesu modelowania mikroskopowego również została zawarta w tym rozdziale.

W rozdziale szóstym przedstawiono charakterystykę podejścia odpornego na losową zmienność parametrów modelu wybranego problemu wyznaczania tras pojazdów. Analiza ta została dokonana przez porównanie otrzymanych rozwiązań na bazie proponowanej metodyki z rozwiązaniami popularnych podejść - deterministycznym i stochastycznym. Badania wykonano na serii zbiorów danych, w których założono losowy stopień realizacji niepewności.

Ostatni rozdział to podsumowanie i weryfikacja osiągniętych celów, wskazanie pozytywnych i negatywnych aspektów zaprezentowanej metodyki oraz wskazanie kierunków dalszych badań.

Praca została uzupełniona o bibliografię, spis rysunków i tabel oraz dwa załączniki. Pierwszy załącznik zawiera matematyczny model dla wyznaczania dolnej i górnej granicy zmienności wybranych kryteriów cząstkowych globalnej funkcji celu. Drugi załącznik prezentuje wyciągi z otrzymanych wyników w postaci tabelarycznej.

1.3 WYKAZ NAJWAŻNIEJSZYCH OZNACZEŃ

SKRÓT NAZW PROBLEMÓW DECYZYJNYCH

VRP-STW	Problem wyznaczania tras pojazdów, w którym uwzględniono elastyczne okna czasowe obsługi oraz jednoczesne rozwożenie i zbieranie towarów (ang. Pickup and Delivery Vehicle Routing Problem with Soft Time Windows)
VRP	Rodzina zagadnień dotyczących wyznaczania tras pojazdów (ang. Vehicle Routing Problem)
TSP	Problem komiwojażera (ang. Traveling Salesman Problem)
TD-VRP-STW	Problem wyznaczania tras pojazdów, w którym uwzględniono elastyczne okna czasowe obsługi oraz jednoczesne rozwożenie i zbieranie towarów, gdzie czas przejazdu zależy od wartości czasu (ang. Time-Dependent Pickup and Delivery Vehicle Routing Problem with Soft Time Windows)
SPP	Problem najkrótszej ścieżki (ang. Shortest Path Problem)
R-VRP-STW	Problem wyznaczania tras pojazdów, w którym uwzględniono elastyczne okna czasowe obsługi oraz jednoczesne rozwożenie i zbieranie towarów (ang. Robust Pickup and Delivery Vehicle Routing Problem with Soft Time Windows), który posiada cechy odporności na wahania wartości parametrów modelu.
R-VRP	Rodzina zagadnień dotyczących wyznaczania odpornych tras pojazdów (ang. Robust Vehicle Routing Problem), które posiadają cechy odporności na wahania wartości parametrów modelu.
R-TD-VRP-STW	Problem wyznaczania tras pojazdów, w którym uwzględniono elastyczne okna czasowe obsługi oraz jednoczesne rozwożenie i zbieranie towarów, gdzie czas przejazdu zależy od wartości czasu (ang. Robust Time-Dependent Pickup and Delivery Vehicle Routing Problem with Soft Time Windows), który posiada cechy odporności na wahania wartości parametrów modelu.
R-SPP	Problem najkrótszej ścieżki (ang. Robust Shortest Path Problem), który posiada cechy odporności na wahania wartości parametrów modelu.

OZNACZENIA MODELI MATEMATYCZNYCH

MIP_u	Ogólny niepewny model programowania całkowitoliczbowego
PL_u	Niepewny model programowania liniowego
RC_{MIP}	Odporny odpowiednik niepewnego modelu programowania całkowitoliczbowego MIP_u
RC_{MIP}^e	Ekwiwalentny model RC_{MIP}
VRP^T	Model matematyczny problemu wyznaczania tras pojazdów zależnego od czasu, w którym uwzględniono elastyczne okna czasowe obsługi, wsteczne przepływy towarów oraz pięć kryteriów minimalizacji
$nVRP^T$	Model matematyczny VRP^T z normalizowaną funkcją kryterialną, która jest sumą znormalizowanych pięciu pod-kryteriów
MIP	Ogólny model programowania całkowitoliczbowego
PL	Ogólny model programowania liniowego
RC	Model odpornego odpowiednika niepewnego modelu PL_u , gdzie wszystkie dane macierzy \tilde{D} są poddane losowym perturbacjom
$PL1_u$	Niepewny model programowania liniowego, w którym funkcja celu jest niepoddana losowym perturbacjom
$RC1$	Model odpornego odpowiednika niepewnego modelu PL_u , gdzie tylko funkcja kryterialna jest niepoddana wahaniom danych modelu, przy czym każde z ograniczeń modelu posiada swój indywidualny zbiór niepewności.
$RC2$	Model odpornego odpowiednika niepewnego modelu PL_u , gdzie tylko funkcja kryterialna jest niepoddana wahaniom danych modelu, przy czym dla wszystkich ograniczeń określono wspólny zbiór niepewności danych.
SPP^T	Model dwukryterialnego problemu najkrótszej ścieżki, który jest zależny od czasu rozpoczęcia okna czasowego wierzchołka startowego ścieżki.
(RC_{SPP})	Odporny model dwukryterialnego problemu najkrótszej ścieżki
(RC_{SPP}^e)	Dwukryterialny, ekwiwalentny model odpornego modelu (RC_{SPP})
$(nVRP1)$	Model matematyczny problemu wyznaczania tras pojazdów, w którym uwzględniono elastyczne okna czasowe obsługi, wsteczne przepływy towarów oraz cztery znormalizowane kryteria minimalizacji funkcji celu
$(nVRP2)$	Model matematyczny problemu wyznaczania tras pojazdów, w którym uwzględniono elastyczne okna czasowe obsługi, wsteczne przepływy towarów oraz pięć znormalizowanych kryteriów minimalizacji funkcji celu

OZNACZENIA ZBIORÓW

AP_K	Rozszerzony zbiór skierowanych łuków grafu o dodatkowe sztuczne, bezpośrednie połączenia, reprezentujące odcinki wejściowe do K-tej liczby magazynów powrotnych
GP_K	Rozszerzony graf skierowany GP o dodatkowe wirtualne magazyny powrotne
$TW^\#$	Zbiór przedziałów czasowych $[e_i^\#, l_i^\#]$, oznaczających, odpowiednio, najwcześniejszy oraz najpóźniejszy możliwy czas rozpoczęcia obsługi transportowej, przy czym: $e_i^\# \leq e_i \wedge l_i \leq l_i^\#$, które tworzą tzw. elastyczne okna czasowe obsługi
VP_K	Rozszerzony zbiór indeksów wierzchołków grafu o dodatkowe indeksy sztucznych wierzchołków, reprezentujące K-tą liczbę magazynów powrotnych dla K-tej liczby pojazdów
Z^{NB}	"Niepewność w budżecie": zbiór losowych perturbacji modelu niepewnego (PL_u) określona przez przecięcie $\ \cdot\ _\infty \leq 1$ oraz $\ \cdot\ _1 \leq \gamma$

AP	Zbiór skierowanych łuków grafu, oznaczających bezpośrednie połączenia między wierzchołkami grafu GP
AS	Zbiór skierowanych łuków grafu, o interpretacji bezpośredniego połączenia pomiędzy węzłami sieci drogowej tj. odcinki sieci drogowej
GP	Skierowany graf reprezentujący bezpośrednie połączenia pomiędzy klientami oraz pomiędzy klientami i magazynem
GS	Skierowany graf reprezentujący rzeczywistą sieć drogową miasta
M	Zbiór indeksów m ograniczeń modeli: (PL) oraz (MIP) oraz ich niepewnych sformułowań
N	Zbiór indeksów n zmiennych modeli: (PL) oraz (MIP) oraz ich niepewnych sformułowań
NI	Zbiór indeksów ni zmiennych, które są całkowitoliczbowe w modelu (MIP) oraz ich niepewnych sformułowań
T	Zbiór indeksów interwałów czasowych
TI	Zbiór przedziałów jednostronnie domkniętych $\langle t_{i\tau} \rangle$ definiujących granice interwałów czasowych
TW	Zbiór przedziałów czasowych $[e_i, l_i]$, oznaczających, odpowiednio, najwcześniejszy oraz najpóźniejszy możliwy czas rozpoczęcia obsługi transportowej i-tego klienta, które tworzą tzw. sztywne okna czasowe obsługi
VP	Zbiór wierzchołków grafu, reprezentujący klientów zgłaszających popyt i/lub podaż na towary wraz z magazynem
VS	Zbiór wierzchołków grafu, reprezentujące węzły transportowe sieci drogowej
\mathcal{L}	Zbiór indeksów potencjalnych, losowych scenariuszy zaburzeń zbioru losowych perturbacji \mathcal{Z}
\mathcal{U}	Zbiór niepewności danych macierzy D modelu ($PL_{\mathcal{U}}$)
\mathcal{Z}	Zbiór losowych perturbacji modelu niepewnego ($PL_{\mathcal{U}}$) w przestrzeni: $\mathcal{Z} \subset \mathbb{R}^{ \mathcal{L} }$
\mathcal{Z}^{SP}	Zbiór losowych perturbacji modelu niepewnego (SPP) opisany założeniami "niepewności w ramach budżetu"
Ω	Zbiór wag kryteriów cząstkowych w funkcji kryterialnej
F_{norm}^{VRP}	Zbiór wartości minimalnych oraz maksymalnych, jakie może przyjąć z osobna dana funkcja kryterium cząstkowego, wykorzystywanych do normalizacji funkcji celu dla modeli ($nVRP$) oraz ($nVRP^T$)

OZNACZENIA MACIERZY I WEKTORÓW

DD_K	Rozszerzona macierz wartości $dd_{ij} > 0, \forall (i, j) \in AP_K \wedge \forall \tau \in T$ o interpretacji odległości bezpośredniej pomiędzy wierzchołkami (i, j)
TT_K	Rozszerzona macierz wartości $tt_{ij\tau} \geq 0, \forall (i, j) \in AP_K \wedge \forall \tau \in T$ o interpretacji czasu przejazdu pomiędzy wierzchołkami (i, j) w danym τ interwale czasowym
A	Macierz wartości: a_{ij} o interpretacji współczynników ograniczeń modelu (PL) oraz modelu (MIP) gdzie i-ty wiersz odpowiada i-temu ograniczeniu, a j-ta kolumna odpowiada j-tej zmiennej problemu
B1	Macierz tzw. "dużych liczb" $[b_{1ij}]$, które można rozumieć, jako maksymalny możliwy czas zakończenia ścieżki pomiędzy parą punktów (i, j) plus maksymalny czas przejazdu w sieci na odcinku (i, j) plus maksymalny czas obsługi i-tego klienta
D	Macierz danych modelu (PL) oraz modelu (MIP), składająca się z: A, b, c, g

DD	Macierz wartości: $dd_{ij} \geq 0, \forall (i, j) \in \mathbf{AP} \wedge \forall \tau \in \mathbf{T}$ o interpretacji bezpośredniej odległości pomiędzy wierzchołkami (i, j)
TT	Macierz wartości: $tt_{ij\tau} \geq 0, \forall (i, j) \in \mathbf{AP} \wedge \forall \tau \in \mathbf{T}$ o interpretacji czasu przejazdu pomiędzy wierzchołkami (i, j) w danym τ interwale czasowym
b	Wektor wartości: b_i o interpretacji wyrazów wolnych prawej strony ograniczeń modelu (PL) oraz modelu (MIP) dla $i = 1, \dots, m$
c	Wektor wartości: c_j o interpretacji współczynników funkcji kryterialnej modelu (PL) oraz modelu (MIP) dla $j = 1, \dots, n$
d	Wektor wartości d_i o interpretacji nieujemnego popytu na towary zgłaszanego przez i -tego klienta
lb, ub	Wektory wartości lb_j, ub_j o interpretacji, odpowiednio, dolnego i górnego ograniczenia dla i -tej zmiennej modelu (MIP) oraz jego niepewnego i odpornego sformułowania
s	Wektor wartości s_i o interpretacji nieujemnej podaży na towary zgłaszane przez i -tego klienta
st	Wektor wartości st_i o interpretacji nieujemnego czasu obsługi transportowej i -tego klienta
x	Wektor zmiennych decyzyjnych x_j modelu (PL) oraz modelu (MIP) oraz ich niepewnych i odpornych sformułowań
Γ	Wektor parametrów $[\Gamma_i]$ kontrolujących poziom konserwatywności i -tego ograniczenia modelu (RC_{MIP})
η	Macierz perturbacji przyjmująca swoje wartości η_{ij} w zbiorze perturbacji \mathcal{Z}^{NB}
ξ	Wektor perturbacji przyjmujący swoje wartości ξ_ρ w zbiorze perturbacji \mathcal{Z}
TT^{SP}	Macierz wartości: $tt_{ij\tau}^{SP} \geq 0, \forall (i, j) \in \mathbf{AS} \wedge \forall \tau \in \mathbf{T}$ o interpretacji czasu przejazdu pomiędzy wierzchołkami (i, j) w danym τ interwale czasowym
DD^{SP}	Macierz wartości: $dd_{ij}^{SP} \geq 0, \forall (i, j) \in \mathbf{AS} \wedge \forall \tau \in \mathbf{T}$ o interpretacji bezpośredniej odległości pomiędzy wierzchołkami (i, j)
TT^{SP}_{e_{org}}	Macierz wartości: $tt_{ij}^{SP}(\tau_{e_{org}})$, gdzie $\tau_{e_{org}}$ jest indeksem interwału czasowego w zakresie, którego znajduje się początek okna czasowego e_{org} wierzchołka startowego org najkrótszej ścieżki
η^{SP}	Macierz perturbacji przyjmująca swoje wartości η_{ij}^{SP} w zbiorze perturbacji \mathcal{Z}^{SP}
ta	Wektor zmiennych z wartościami $[ta_i], \forall i \in \mathbf{VP}_K$ o interpretacji czasu przyjazdu do i -tego klienta

POZOSTAŁE OZNACZENIA

$Fa_1, Fa_2, Fa_3, Fa_4, Fa_5$	Wartości minimalne, jakie mogą przyjąć funkcje kryterium cząstkowego z osobna, dla odpowiednio: łącznego czasu trwania tras, łącznego dystansu tras, łącznego czasu oczekiwania, łącznego czasu opóźnienia oraz liczby pojazdów
$Fb_1, Fb_2, Fb_3, Fb_4, Fb_5$	Wartości maksymalne, jakie mogą przyjąć funkcje kryterium cząstkowego z osobna, dla odpowiednio: łącznego czasu trwania tras, łącznego dystansu tras, łącznego czasu oczekiwania, łącznego czasu opóźnienia oraz liczby pojazdów
U_τ	Wartość określająca górny zakres interwału czasowego τ
$ct_{ij}(\tau)$	Funkcja skokowa czasu przejazdu łuku (i, j) zależna od wartości τ interwału czasowego

f_1, f_2, f_3, f_4, f_5	Kryteria cząstkowe o interpretacji, odpowiednio: łączny czas tras, łączny dystans tras, łączny czas zbyt wczesnego przyjazdów pojazdu do klientów, łączny czas zbyt późnego przyjazdu pojazdów do klientów oraz łączna liczba użytych pojazdów w rozwiązaniu
ta_i	Zmienna modelu ($nVRP^T$) określająca czas przyjazdu pojazdu do i-tego klient
$x_{ij\tau}$	Zmienna binarna modelu ($nVRP^T$) o interpretacji, czy dany łuk (i, j) znajduje się w rozwiązaniu w interwale czasowym τ
df_{ij}	Zmienna modelu ($nVRP^T$) określająca ilość towaru rozwożonego, znajdującego się w pojeździe przejeżdżającego przez łuk (i, j) - przepływ towarów w przód
sf_{ij}	Zmienna modelu ($nVRP^T$) określająca ilość towaru zbieranego, znajdującego się w pojeździe przejeżdżającego przez łuk (i, j) - przepływ rewersyjny
$\delta_1, \delta_2, \delta_3, \delta_4, \delta_5$	Parametry funkcji kryterialnej o interpretacji ekonomicznego, jednostkowego odpowiednio: kosztu jednej wozogodziny, kosztu jednego wozokilometra, kosztu związany z wcześniejszym przyjazdem pojazdu do klienta, kosztu związany z późniejszym przyjazdem pojazdu do klienta oraz operacyjnego kosztu użycia jednego pojazdu
$\omega_1, \omega_2, \omega_3, \omega_4, \omega_5$	Wartości wag dla poszczególnych kryteriów cząstkowych, przy czym: $\sum_{i=1}^5 \omega_i = 1$
$[E, L]$	Przedział czasowy oznaczający odpowiednio, najwcześniejszy możliwy wyjazd pojazdów z magazynu i najpóźniejszy możliwy powrót pojazdów do magazynu.
γ	Parametr kontrolujący poziom konserwatyzmu rozwiązania
$B2$	Duża liczba, która może być określona przez maksymalny czas zakończenia każdej trasy
K	Wartość określająca liczbę pojazdów znajdującą się w dyspozycji
Q	Maksymalna ładowność pojazdów
g	Stała funkcji kryterialnej problemu (PL)
$\{org, des\}$	Punkt startowy i końcowy w problemie najkrótszej ścieżki
x_{ij}^{SP}	Zmienna binarna modelu (SPP^T) o interpretacji, czy dany łuk (i, j) znajduje się w rozwiązaniu (w ścieżce)
f_1^{SP}, f_2^{SP}	Funkcje celu modelu (SPP^T) o interpretacji, odpowiednio: łączny czas ścieżki i łączna długość ścieżki
Fa_1^{SP}, Fb_1^{SP}	Minimalną i maksymalną długość ścieżki w danej sieci wyrażoną jednostką odległości w modelu (SPP^T)
Fa_2^{SP}, Fb_2^{SP}	Minimalną i maksymalną długość trwania ścieżki dla danej sieci wyrażoną jednostką czasu w modelu (SPP^T)
ω^{SP}	Wartość wagi kryterium czasu w modelu (SPP^T)
I^{SP}	Parametr sterujący poziom konserwatyzmu rozwiązania odpornego modelu (RC_{SPP})
$\tau_{e_{org}}$	Indeks interwału czasowego: $\tau_{e_{org}} \in T$ w zakresie, którego znajduje się początek okna czasowego e_{org} wierzchołka startowego org najkrótszej ścieżki.
α_{ij}^{SP}	Macierz zmiennych dualnych modelu (RC_{SPP})
θ^{SP}	Zmienna dualna modelu (RC_{MIP})
α_{ij}	Macierz zmiennych dualnych modelu (RC_{MIP})
θ_i	Wektor zmiennych dualnych modelu (RC_{MIP})
y_{ij}^{SP}	Dodatkową zmienną modelu (RC_{MIP}^*), która odpowiada optymalnemu rozwiązaniu

	dla każdego wpisu $ x_{ij}^{SP} $ modelu (RC_{MIP}^*)
y_j	Dodatkową zmienną modelu (RC_{MIP}^*) , która odpowiada optymalnemu rozwiązaniu $ x_j^* $ modelu (RC_{MIP}^*)

AKCENTY W OZNACZENIACH ZMIENNYCH

Tylda: \sim	Zmienne niepewne lub wartości niepewne np. \tilde{c} oznacza wektor niepewnych wartości współczynników funkcji kryterialnej
Kreska: $-$	Nominalne wartości danych reprezentujące strukturę afiniczną niepewnych wartości danych modelu; może to być np. wartość oczekiwana
Daszek: $\hat{}$	Wartości danych reprezentujące potencjalny zakres zmian, wykorzystywane przy opisie afinicznym niepewnych wartości danych
Gwiazdka: $*$	Wartość optymalna danego problemu lub wektor zmiennych z rozwiązaniem optymalnym

2 DYSTRYBUCJA TOWARÓW NA OBSZARACH MIEJSKICH

2.1 CHARAKTERYSTYKA MIEJSKIEJ DYSTRYBUCJI TOWARÓW

W ostatnich latach w literaturze przedmiotu można zaobserwować trend do opisu transportu towarowego w miastach jako elementu systemu logistycznego miasta, w którym występują procesy logistyczne². Ze względu na wielo-obszarowy charakter funkcjonowania miasta system logistyczny miasta prowadzi badania i generuje oddziaływania między innymi w zakresie [38, 150]:

- organizacji obsługi logistycznej jednostek gospodarczych,
- organizacji pasażerskiego transportu miejskiego oraz podmiejskiego,
- organizacji towarowego transportu miejskiego, w tym procesy zaopatrzenia, dystrybucji, czy też składowania towarów,
- problematyki utylizacji odpadów komunalnych,
- organizacji sieci telekomunikacyjnej,
- zaopatrywania w media (woda, energia elektryczna i ciepła, gaz),
- koordynacji miejskiego transportu z transportem regionalnym (aglomeracyjnym).

W ujęciu logistyczno-systemowym, miasto może być oceniane na podstawie efektywności realizacji łańcuchów (lub sieci) logistycznych oraz przepływów strumieni osób, materiałów, informacji, czy energii. Zarządzanie, organizowanie, sterowanie oraz kontrola procesów przepływów w łańcuchach logistycznych jest podstawowym elementem koncepcji logistyki miasta [150]. Strumienie przepływające przez miasto, z punktu widzenia logistyki, charakteryzują się przebiegiem w przestrzeni (długość strumienia, lokalizacja źródła/celu strumienia) oraz przebiegiem w czasie (zmiana intensywności, szczyty komunikacyjne, restrykcje czasowe dotyczące obsługi danego obszaru).

Bardzo ważnym elementem systemu logistycznego miasta jest jego infrastruktura techniczna. Do infrastruktury technicznej miasta zalicza się infrastrukturę: drogową, transportową, telekomunikacyjną oraz magazynową. Infrastruktura drogową jest najważniejsza, ponieważ jest często wyznacznikiem poziomu rozwoju miasta oraz poziomu efektywnego jej wykorzystania, poprzez np. określenie zdolności przewozowej systemu transportowego (odnosi się to do osób, towarów oraz informacji). Poprawne zdefiniowanie wskaźników wykorzystania infrastruktury miasta umożliwi właściwe zarządzanie procesami transportowymi i logistycznymi występującymi na danym obszarze. W odniesieniu do transportu towarów, przykładem działania mającego m.in. na celu określenie wspomnianych wskaźników efektywności

² Zbiór procesów logistycznych miasta można zdefiniować, jako ogół procesów występujących w systemie miasta, którego celem jest efektywne i racjonalne wykonanie określonych funkcji dla sprawnej obsługi użytkowników miasta i jego rozwoju [150].

był projekt BESTUFS³, gdzie zdefiniowano 46 wskaźników służących do oceny systemu transportowego miasta. Podzielono je na 6 grup tematycznych [117]:

- wielkość strumieni towarów,
- flota transportowa, realizująca usługi towarowe na terenach miasta,
- miejskie przesyłki (rodzaj przesyłek i usług, źródła i cel przesyłek, długość trasy, itp.),
- udział w gospodarce miasta,
- środowisko (wielkość emisji spalin, hałasu, zużycie paliwa),
- bezpieczeństwo.

Przedstawiony projekt i jego wyniki są przykładem spojrzenia na miasto nie przez pryzmat samych procesów transportowych, ale jako na obiekt całościowo. Wyraża się to poprzez uwzględnienie wpływu tych procesów na inne obiekty miasta oraz związanymi z nimi sprzężeń zwrotnych, czyli wpływu jak inne obiekty miasta reagują na daną realizację procesu transportowego. Takie spojrzenie na system transportowy miasta doprowadziło do powstania pojęcia logistyki miejskiej (ang. City Logistics). Koncepcja logistyki miejskiej została stworzona na podstawowych założeniach logistycznych, jakimi są: koordynacja działań, orientacja na przepływy towarów oraz analizę systemu przez pryzmat całości tzw. holizm [38]. Obecnie nie funkcjonuje jednoznaczna i właściwa definicja logistyki miejskiej. Sposób definiowania tego pojęcia zależy od obszaru miasta, jaki jest analizowany w danej pracy naukowej, czy też od rodzaju projektu wdrażanego w danym mieście. Dla przykładu: logistyka miejska może oznaczać optymalizowanie przemieszczania towarów w sieci drogowej uwzględniając warunki ruchowe i ekologiczne; logistyka miejska może oznaczać współpracę pomiędzy podmiotami gospodarczymi na terenach miejskich; lub może oznaczać formy zarządzania ruchem towarów czy osób w wybranym podsystemie [150]. Istnieją również koncepcje, które zaprzeczają podstawowym założeniom podejścia logistycznego, a mianowicie założeniu holizmu. Definiowanie logistyki miejskiej, jako organizacji tylko transportu osób lub jako strategii i polityki transportowej na wybranym obszarze miasta np. centrum miasta, powoduje, że wprowadzany jest sztuczny podział obiektu, jakim jest miasto [133]. Wprowadzanie obszarowo poprawnego zarządzania na wybranym fragmencie miasta nie spowoduje, że zostaną wyeliminowane problemy całego miasta. Udrożnienie centrum miasta niekoniecznie przełoży się na udrożnienie całego systemu transportowego miasta, co więcej, w zależności od zastosowanego rozwiązania, możliwe jest, że "wąskie gardła komunikacyjne" i pozornie rozwiązane problemy z centrum miasta przeniosą się na sąsiadujące obszary.

W tabeli 2-1 przedstawiono wybrane definicje logistyki miejskiej, jakie obecnie funkcjonują w literaturze przedmiotu. Wspomniany już projekt BESTUFS, skupiał się tylko na transporcie towarów w mieście, wobec czego stworzona definicja logistyki miejskiej odnosi się tylko i wyłącznie do tego obszaru badań. Definicja zaproponowana przez J. Szołtysek, jest szerszą od poprzedniej, ponieważ uwzględnia ona również przepływy osób oraz informacji, jednakże skupia ona szczególną uwagę na społeczności miasta oraz ekologię. Cele i potrzeby podmiotów gospodarczych są tutaj niewymienione, co może wskazywać, że obowiązkiem

³ Projekt BESTUFS (ang. BEST Urban Freight Solutions) został zrealizowany w latach 2000-2006 i był finansowany przez Komisję Europejską (DG Transport and Energy). Głównym celem projektu było zidentyfikowanie, zebranie, opisanie i przedstawienie dobrych praktyk w zarządzaniu towarowym transportem miejskim.

zarządzania systemem logistycznym miasta leży w gestii zarządzających miastem. Zupełnie inny pogląd na określenie, czym jest logistyka miejska została zaprezentowana przez E. Taniguchi, która jest propagowana przez Instytut Logistyki Miejskiej w Kyoto w Japonii⁴. Wynika z niej, że efektywne zarządzanie transportem w mieście powinno znajdować się po stronie prywatnych podmiotów gospodarczych⁵, a informacje potrzebne do zarządzania powinny być pozyskiwane dzięki nowoczesnym technologiom (biorąc pod uwagę profil badań Instytutu w Kyoto można przypuszczać, że chodzi tu o pozyskiwanie informacji z narzędzi Inteligentnych Systemów Transportowych - dalej ITS). Ostatnią przytoczoną definicją jest zaproponowana przez B. Tundys, która opisuje logistykę miejską dość ogólnie, przedstawia jej cele oraz do jakich elementów systemu się odnosi, jednakże brak w tej formule wskazania, kogo dotyczy i kto jest odpowiedzialny za wdrażanie koncepcji logistyki miejskiej. Pominięto również ważną kwestię - przepływu informacji w systemie miasta.

Tabela 2-1 Wybrane definicje logistyki miejskiej.

AUTOR	DEFINICJA LOGISTYKI MIEJSKIEJ
Projekt BESTUFS [117]	Logistyka miejska odnosi się do szeregu aktywności, które są wynikiem skomplikowanych relacji, występujących pomiędzy różnymi podmiotami (z obszaru produkcji, handlu i dostaw towarów do różnych klientów i mieszkańców), które przejawiają się w formie wewnętrznego transportu lub międzymiastowej dystrybucji towarów, mające istotny wpływ na gospodarkę oraz życie i procesy miasta.
Szołtysek, J. [132]	Ogół procesów zarządzania przepływami osób, ładunków i informacji wewnątrz systemu logistycznego miasta, zgodnie z potrzebami i celami rozwojowymi miasta, z poszanowaniem ochrony środowiska naturalnego, uwzględniając, że miasto jest organizacją społeczną, której nadrzędnym celem jest zaspokajanie potrzeb swoich użytkowników.
E. Taniguchi [141]	Logistyka miejska jest to proces kompleksowej optymalizacji działalności logistycznych i transportowych w obszarach miejskich przez przedsiębiorstwa prywatne wspomaganych zaawansowanymi metodami pozyskiwania informacji o systemie transportowym miasta, z uwzględnieniem warunków ruchowych, poziomu zatłoczenia, bezpieczeństwa oraz zachowaniem oszczędności energii w ramach gospodarki miasta.
B. Tundys [150]	Logistyka miejska to powiązania systemu logistycznego wewnątrz określonego obszaru miejskiego, ze szczególnym uwzględnieniem systemu transportowego obejmującego zarówno przepływy ładunków, jak i osób, które mają na celu efektywnie, optymalnie i ekologicznie koordynować wszelkie przemieszczenia w mieście (i w szczególnych przypadkach wychodzące poza granice administracyjne - np. przewozy z/do gmin ościennych), obejmująca wszelkiego rodzaju komponenty: infrastrukturalne, organizacyjne, informacyjno - technologiczne i ludzkie, biorąc pod uwagę aspekt ekonomiczny, społeczny i ekologiczny.

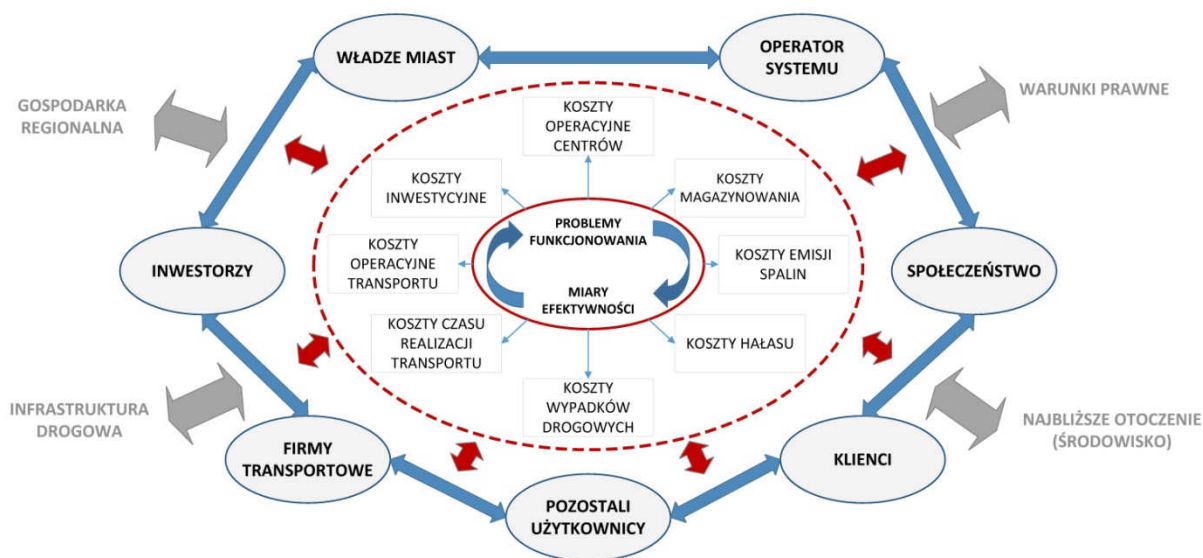
Źródło: opracowanie własne na podstawie:[117, 132, 141, 150].

⁴ Instytut Logistyki Miejskiej w Kyoto (ang. Institute for City Logistics) jest jednym z wiodących ośrodków naukowych, skupiający naukowców z całego świata, prowadzący badania w zakresie optymalizacji procesów transportowych i logistycznych występujących na obszarach miejskich.

⁵ Przeniesienie odpowiedzialności za kształtowanie transportu na prywatne podmioty w polskich warunkach może się wydawać nierealne. Forma tej definicji może wynikać z faktu, że w Japonii i w niektórych krajach zachodniej Europy planowanie transportu w miastach odbywa się przez partnerstwo publiczno-prawne, angażując do współpracy firmy transportowe, kurierskie, administratorów, władze lokalne oraz mieszkańców.

Przedstawiony powyżej, krótki przegląd definicji logistyki miejskiej, wskazuje na fakt dość oczywisty - definiowanie badanego obiektu (tutaj procesów transportowych miasta) zawsze jest subiektywne i nakierowane na cel prowadzonych badań. W związku z tym, że nie jest celem pracy wprowadzanie nowej definicji logistyki miejskiej, autor w dalszych rozważaniach przyjmuje za właściwą definicję zaproponowaną przez E. Taniguchi z kilkoma uwagami. "Kompleksowa optymalizacja działalności logistyczno-transportowych" będzie rozumiana, w odniesieniu tylko do transportu towarów na obszarze miejskim uwzględniając aspekty ekonomiczne, ekologiczne oraz społeczne (fragment "kompleksowa optymalizacja"). Dodatkowo, mając na uwadze fakt, że analizy i pomiary systemu transportowego w polskich miastach w głównej mierze spoczywają na lokalnych władzach i jednostkach zarządzających, uzyskiwanie tych informacji wymaga współpracy prywatnych firm z władzami miasta (zwrot "Metody pozyskiwania informacji o systemie transportowym miasta"). Rozumienie w taki sposób terminu "logistyki miejskiej" nieco rozszerza oryginalną definicję, jednak ma to na celu zwrócenie uwagi, że prywatne przedsiębiorstwa nie są wyizolowanym uczestnikiem systemu transportowego i logistycznego miasta.

Logistyka miejska jest skomplikowanym i złożonym systemem, w którego skład wchodzi wielu aktorów (uczestników) procesu transportowego i procesu logistycznego - uproszczone relacje pomiędzy aktorami przedstawia rysunek 2.1. Głównymi uczestnikami logistyki miejskiej są klienci oraz przewoźnicy rozwożący i zbierający towary z różnych lokalizacji. Struktura logistyki miasta jest kreowana i tworzona przez czynniki zewnętrzne takie jak lokalna i regionalna gospodarka, obowiązujące warunki prawne, charakterystyka infrastruktury technicznej miasta oraz otoczenie, w postaci środowiska naturalnego.



Rysunek 2.1 Główni aktorzy i relacje systemu logistycznego miasta w odniesieniu do transportu towarów.

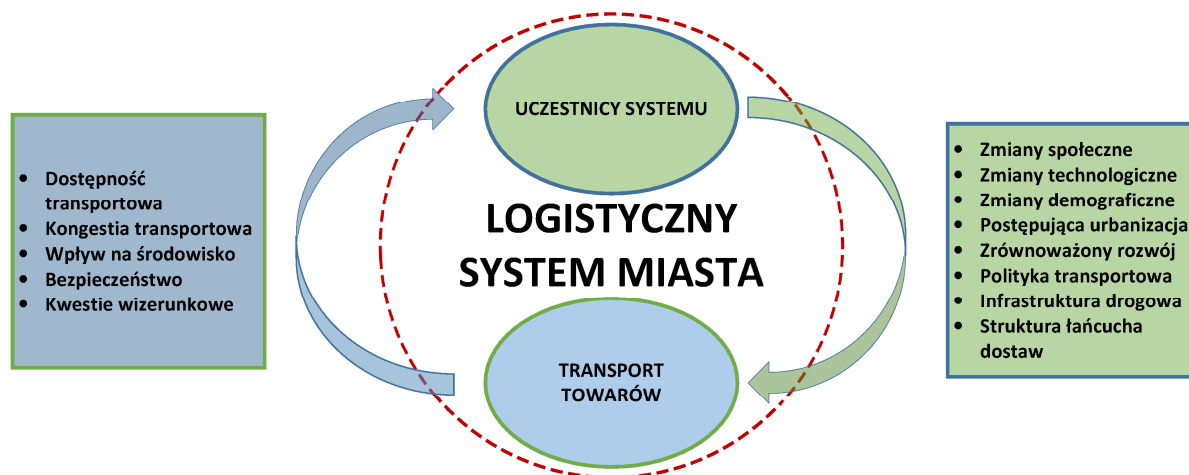
Źródło: opracowanie własne na podstawie [117]

Każda realizacja transportu towarów w mieście charakteryzuje się specyficznymi problemami funkcjonowania, które są wynikiem oddziaływania pozostałych uczestników systemu. Oddziaływanie te mogą być wyrażone w postaci żądanych miar efektywności, które z kolei można przełożyć na koszty generowane przez transport towarów w mieście. Część kosztów jest bezpośrednia np. koszt operacyjny transportu będzie bezpośrednim kosztem firmy trans-

portowej, a część kosztów jest kosztami pośrednimi, np. koszt emisji spalin będzie kosztem pośrednim dla społeczeństwa miasta (realizowany w podatkach lub opłatach wjazdowych na wybrane obszary miasta) [44, 117]. Szczegółową charakterystykę wpływu transportu towarów na otoczenie przedstawiono w następnym podrozdziale.

2.1.1 WPLYW PRZEWOZU TOWARÓW W MIASTACH NA SYSTEM LOGISTYCZNY MIASTA

Transport towarów w mieście jest zagadnieniem, którego charakter i organizacja są odzworowaniem procesów występujących w społeczeństwie. Istotne trendy w transporcie towarowym odnoszą się do zmian społecznych, technologicznych oraz organizacyjnych. Zmiany organizacyjne są rozumiane jako zmiany w koncepcjach prowadzonych polityk transportowych, które w ostatnich latach skoncentrowały się na bardziej otwartych procesach konsultacyjnych ze społeczeństwem. W raporcie dotyczącym transportu towarów w XXI wieku przygotowanym przez Organizację Współpracy Gospodarczej i Rozwoju (ang. Organization for Economic Co-operation and Development - dalej OECD) [104] przedstawiono problemy transportowe, które wpływały, wpływają i będą wpływać na sposób organizacji transportu w miastach. Jednakże sam proces transportowy w mieście ze względu na swoją specyfikę również wpływa na środowisko naturalne oraz pozostałych uczestników systemu logistycznego. Niestety oddziaływanie to jest negatywne i często generuje tzw. zewnętrzne koszty transportu. Do zewnętrznych kosztów transportu można zaliczyć m.in. koszt emisji spalin, koszt emitowanego hałasu, koszt wypadków drogowych oraz ekonomiczny koszt, jakim jest wizerunek miasta. Na rysunku 2.2 przedstawiono, jakie czynniki wpływają na kształtowanie procesu transportowego oraz jak ten proces oddziałuje na pozostałe elementy systemu logistycznego miasta. Założono, że środowisko naturalne występuje z zbiorze "Uczestnicy systemu".



Rysunek 2.2 Relacja i czynniki wpływu pomiędzy transportem towarów w mieście a pozostałymi uczestnikami.

Źródło: opracowanie własne na podstawie [30, 104, 140].

Zmiany społeczne

Koniec XX wieku to zmiana społeczeństwa przemysłowego w społeczeństwo postindustrialne. Upraszczając opis tego zjawiska, można innymi słowy powiedzieć, że społeczeństwo odchodzi od technologii maszyn i zmierza w kierunku społeczeństwa informatycznego, w którym wiedza i informacja jest kluczowym elementem. Najważniejszymi cechami takiego społeczeństwa są: nacisk na dostęp do wszelkiej informacji, wzrost zapotrzebowanie na

usługi, globalizacja oraz rozwój technologiczny. Nacisk na dostęp do informacji wraz z rozwojem technologii, spowodował, że firmy transportowe, aby nadażyć za obowiązującymi trendami musieli zmienić swoją ofertę usług oraz sposobu realizacji transportu. Społeczeństwo postindustrialne w silnym stopniu zależy od przepływu informacji, głównie w postaci cyfrowej transmisji. Taki typ gospodarki, niemniej jednak, w dużym stopniu zależy od efektywnego i elastycznego transportu towarów [104]. Przykładem tutaj może być tworzenie systemów informatycznych, które umożliwiają śledzenie przesyłek, sprawdzenie planowanego terminu dostarczenia, czy też warunków, w jakich znajduje się przesyłka (wilgotność, temperatura powietrza, obecne położenie)⁶. Takie rozwiązania wymagają od firm transportowych wyposażenia się w nowoczesne technologie i urządzenia lokalizacyjne oraz specjalistyczne urządzenia dające możliwość tworzenia nowych usług.

Zmiany technologiczne

Technologie telematyczne pełnią kluczową rolę w rozwoju efektywnego transportu towarów. Inteligentne Systemy Transportowe jest to zbiór różnorodnych technologii telekomunikacyjnych, informatycznych, automatycznych, pomiarowych oraz metod zarządzania transportem w celu zwiększenia efektywności systemu transportowego z jednoczesną ochroną środowiska naturalnego i społecznego człowieka. Jak wskazuje E. Taniguchi [139], rozwój ITS, technologii informacyjnych oraz społecznej odpowiedzialności biznesu (ang. Corporate Social Responsibility) istotnie oddziałują na modelowanie zachowań uczestników systemu logistycznego miasta. Głównie dotyczy to firm kurierskich i mieszkańców. Technologie ITS dają możliwość pozyskiwania parametrów ruchu miejskiego oraz pozyskania informacji o położeniu pojazdów w mieście (współrzędne geograficzne, aktualna prędkość, czas operacyjny, przyspieszenie, itp.). Dostępność tych danych umożliwia właściwe zaplanowanie tras pojazdów oraz harmonogramów pracy kierowcom i pojazdom. Dodatkowo posiadanie takich danych może być przekazywane również swoim klientom, poprzez wspomniany już system śledzenia przesyłek. Z kolei, tzw. odpowiedzialność społeczna biznesu, wymusza zmiany zachowań (kształtowania transportu) firm transportowych, aby czynniki środowiskowe i ekologiczne również były uwzględniane przy planowaniu tras. Tak więc lokalne społeczeństwo oraz władze miast przenoszą część odpowiedzialności za środowisko naturalne na firmy transportowe, które realizują transport na obszarach miejskich.

Zmiany demograficzne

Zmiany w strukturze demograficznej społeczeństwa (społeczeństwo starzejące się) oraz zwiększający się indywidualizm społeczeństwa istotnie wpływają na zachowania konsumentów oraz prowadzą do zasadniczych zmian na rynku transportowym. Zmiany zachowań konsumentów z kolei wpływają na strukturę funkcjonowania dystrybucji towarów. Jednorodny rynek masowy, jaki występował po II wojnie światowej, przekształcił się w rynek indywidualny. Tendencja ta przejawia się w formie rozproszonych i podzielonych przepływów towarów - występuje duży wzrost przesyłek i dostaw zawierających małe porcje towarów. Niewielka ilość zamawianego towaru przekłada się w dużą częstotliwość przesyłek, co automatycznie generuje zwiększenie liczby przejazdów przez pojazdy logistyki miejskiej⁷. Egzempli-

⁶ Na podstawie przeglądu oferty międzynarodowej firmy kurierskiej.

⁷ Przez pojęcie "pojazd logistyki miejskiej" będzie rozumiane ogół pojazdów, które uczestniczą w procesach transportowych i logistycznych w systemie logistyki miejskiej.

fikacją takiego stanu rzeczy jest gwałtowny rozwój handlu elektronicznego (ang. e-commerce). Jak pokazuje raport o handlu elektronicznym [70] szacowany udział tego rodzaju handlu w całej sprzedaży detalicznej w Polsce w 2013 roku wynosił średnio 4,53% (dla porównania w 2011 roku wynosił on 3,1%, a w Niemczech udział wynosił 9%). Jednak dynamika wzrostu handlu elektronicznego w Polsce jest jednak największa w Europie i wynosi, w zależności od opracowania, od 17 do 24% w ciągu jednego roku. Oznacza to, że handel elektroniczny w Polsce dopiero jest w fazie rozwoju. Jak ten dynamiczny rozwój wpływa na transport w miastach? Cechą charakterystyczną tego rodzaju biznesu jest oferowanie szybkich przesyłek, zazwyczaj metodą pod drzwi klienta. W opracowaniu [153] przedstawiono porównanie charakterystyki tradycyjnego dostarczania towarów (do sklepów stacjonarnych) z cechami przesyłek z handlu elektronicznego. Porównanie przedstawia tabela 2-2.

Tabela 2-2 Różnice pomiędzy tradycyjnymi dostawami, a dostawami handlu elektronicznego.

TRADYCYJNE DOSTAWY		HANDEL ELEKTRONICZNY
Dostawa do sklepu	"Ostatni kilometr"	Dostawa bezpośrednia
Duże ilości towarów	Małe ilości towarów	Pojedyncze sztuki
Jednorodny ładunek	Heterogeniczny ładunek	Heterogeniczny ładunek
Duże pojazdy (o wysokiej ładowności)	Pojazdy osobowe	Pojazdy o małej ładowności
Jedno zatrzymanie pojazdu	Jedno lub kilka zatrzymań pojazdu	Wiele zatrzymań pojazdu
Stałe trasy do sklepów	Trasy pomiędzy miejscem zamieszkania a sklepem	Wiele tras, pojazd porusza się po obszarze zamieszkałym
Brak błędów w dostawach	Brak błędów w dostawach	Wiele błędów w dostawach

Źródło: opracowanie własne na podstawie [153].

Zauważalne trendy wskazują, że handel elektroniczny prowadzi do wzrostu transportu towarowego pod względem wykonanej pracy przewozowej, wyrażonej w tonokilometrach, oraz do zwiększenia fragmentaryzacji przesyłek szczególnie w miejskiej dystrybucji [104]. Bez wprowadzenia odpowiednich narzędzi, które umożliwiają konsolidację przepływów towarów do i z obszarów miejskich, rozwój e-handlu może przynieść dalszą degradację środowiska oraz zwiększające się zatłoczenie. Jak wskazuje raport OECD możliwymi narzędziami do zniwelowania tego efektu jest kooperacja firm transportowych, konsolidacja ładunków poprzez miejskie centra konsolidacji oraz zastosowanie metod optymalizacji przebiegu tras.

Postępująca urbanizacja

Na świecie w połowie 2014 roku ponad połowa ludności żyła w miastach lub obszarach zurbanizowanych. W Europie udział ten wynosił 73,4%, a w Polsce 60,6% ogółu ludności to mieszkańcy miast [151]. W odniesieniu do wysokiej gęstości zaludnienia w miastach, ograniczonej przestrzeni miejskiej, limitowanej przepustowości infrastruktury drogowej oraz istniejących ograniczeń środowiskowych i ekologicznych, miejski transport towarowy musi radzić sobie z wieloma trudnościami. Większa liczba mieszkańców miast automatycznie generuje większą mobilność mieszkańców. Dla przykładu liczba zarejestrowanych pojazdów osobowych przypadających na 1000 mieszkańców w 2003 roku w Polsce wynosiła prawie 300, a

w 2013 roku wskaźnik ten wynosił ponad 500 [63]. Efektem postępującej urbanizacji jest obniżający się poziom życia mieszkańców miast [97, 104]. Sytuacja ta prowadzi do zwiększenia liczby pojazdów w miastach, większej liczby wykonywanych podróży, co bezpośrednio zwiększa poziom zatłoczenia infrastruktury drogowej. W konsekwencji przejawia się to w postaci występowania kongestii transportowej⁸. Kongestia transportowa dotyczy wszystkich uczestników ruchu - osób i towarów. Wpływ kongestii jest dość oczywisty - zwiększa się czas przejazdu pojazdów, co może być również utożsamione z całkowitym czasem przebywania pojazdu w systemie transportowym miasta. Celem wspólnym dla wszystkich uczestników systemu logistycznego jest minimalizacja tego czasu. Zmierzenie ile traci się czasu przez występowanie kongestii jest dość trudne. Ciekawym podejściem, które próbuje opisać ten parametr jest raport o korkach w 7 największych miastach Polski, przygotowanym przez Deloitte i Targeo.pl [45]. Raport ten przedstawia m.in. wskaźnik względnego opóźnienia spowodowanego korkami w stosunku do przejazdu swobodnego bez utrudnień (w między szczycie komunikacyjnym) - tabela 2-3. W analizie statystycznej sprawdzono, jaki jest średni czas opóźnień na 10 km trasy w każdym mieście. Najbardziej zakorkowanym miastem w Polsce jest Kraków i statystycznie każdy pojazd (kierowca) w 2013 roku tracił ponad 22 minuty dziennie. Przekładając tę wartość na flotę pojazdów w firmie kurierskiej można otrzymać spore wartości, które są bezpośrednimi kosztami dla firm.

Tabela 2-3 Średni czas opóźnień spowodowanych występowaniem kongestii w Polskich miastach.

MIASTO\ROK	CZAS [MINUTA/DZIEŃ]		
	2013	2012	2011
Kraków	22:03	21:06	18:29
Wrocław	21:49	20:40	20:14
Poznań	21:06	21:43	23:26
Warszawa	20:43	23:17	25:40
Łódź	18:00	18:06	16:31
Katowice	14:03	15:14	13:34
Gdańsk	14:03	15:14	20:51

Źródło: opracowanie własne na podstawie [45]

Polityka zrównoważonego rozwoju

Zrównoważony rozwój (ang. sustainable development) jest określany jako rozwój "w którym potrzeby obecnego pokolenia mogą być zaspokojone bez zmniejszania szans dla przyszłych pokoleń na ich zaspokojenie" [149]. Wprowadzanie zasady zrównoważonego rozwoju w różne aspekty życia w obecnych czasach jest obowiązkowe. W odniesieniu do

⁸ Kongestia transportowa oznacza przeciążenie i zatłoczenie na szlakach komunikacyjnych. Jest również definiowana jako "różnica w kosztach zasobów między siecią drogową eksploatowaną (funkcjonującą) w obecnych warunkach ruchu a siecią eksploatowaną w idealnych warunkach, gdzie zostały wyeliminowane opóźnienia, ruch odbywa się z maksymalnie bezpieczną prędkością" [107].

zapotrzebowania na transport osób, czy towarów oczekuje się, że poziom zrównoważonego rozwoju będzie zwiększany. Jednakże mając na uwadze negatywny wpływ transportu na otoczenie (degradacja środowiska naturalnego, zatłoczenie, koszty wypadków drogowych oraz wpływ na zdrowie człowieka), wprowadzanie zasady zrównoważenia nie jest możliwe, szczególnie w dłuższej perspektywie. W związku z tym, osiągnięcie zrównoważonego rozwoju w transporcie wymaga takiej jego organizacji, aby w krótkiej i dłuższej perspektywie przynosił korzyści gospodarcze i społeczne, przy jednoczesnym minimalizowaniu negatywnego wpływu na środowisko naturalne i społeczne [104]. W dalszej części podrozdziału rozwinięto ten wątek, przy okazji charakteryzowania wpływu procesu transportowego na otoczenie.

Polityka transportowa

Polityka transportowa miast, która wraz z rozwojem miast staje się coraz bardziej skomplikowana i złożona, jest kolejnym czynnikiem wpływającym na kształtowanie usług i realizacji procesów transportowych. Polityka transportowa miasta ma za zadanie sprostać oczekiwaniom wszystkich uczestników systemu transportowego miasta, które często są rozbieżne (tabela 2-4) oraz odpowiadać na skomplikowane i różnorodne operacje transportu towarów w miastach i z nich wynikających problemów. Przykładem takich działań może być np. wprowadzenie strefy "zero emisji", czy też restrykcje czasowe i wagowe pojazdów dotyczące wjazdu do centrum miasta w celach zaopatrzeniowych. Wprowadzenie takich ograniczeń ma na celu ochronę mieszkańców, czy też architektury miasta, jednak z punktu widzenia firm transportowych mogą one powodować, że realizacja transportu będzie bardziej kosztowna.

Tabela 2-4 Oczekiwania uczestników towarowego systemu transportowego.

UCZESTNIK SYSTEMU TRANSPORTOWEGO	OCZEKIWANIA
Mieszkańcy	- Przyjazne środowisko do życia; - Minimalny wpływ pojazdów dostawczych na funkcjonowanie (szczególnie w porach nocnych); - Dobra dostępność do usług transportowych;
Turyści	- Atrakcyjność turystyczna miasta; - Dostępność parkingowa miasta; - Dostępność transportowa miasta;
Sprzedawcy i podmioty handlowe	- Wysoka rentowność; - Dobra atmosfera sprzedaży;
Przewoźnicy, firmy transportowe	- Dostępność transportowa; - Odpowiednia infrastruktura drogowa np. występowanie zatoczek rozładunkowych; - Efektywność kosztowa; - Atrakcyjne środowisko pracy;

Źródło: opracowanie własne na podstawie: [104]

Infrastruktura drogowa

Powiązany bezpośrednio z polityką transportową, czynnikiem wpływającym na przebieg procesu transportu jest infrastruktura drogowa. Brak występowania zatoczek rozładunkowych, jednokierunkowość ulic, przepustowość oraz zatłoczenie to podstawowe elementy

związane z infrastrukturą, które stwarzają problemy dla firm transportowych. Nie odpowiednie ukształtowanie układu komunikacyjnego, zła polityka transportowa (lub jej brak) oraz wysoki poziom mobilności mieszkańców prowadzą do lokalnego przeciążania sieci drogowej, co istotnie oddziałuje na realizację transportu towarowego. Zwiększony czas przejazdu przez sieć, spowodowany zatłoczeniem, wpływa na zwiększanie się kosztów operacyjnych pojazdu i kierowcy, zwiększanie zużycia paliwa, emisji spalin i hałasu oraz może powodować zmniejszenie poziomu jakości obsługi klienta świadczonej przez firmę transportową.

Struktura łańcucha dostaw

Realizacja transportu często jest elementem większego podsystemu, jakim jest łańcuch dostaw. W zależności od tego jak jest ukształtowana struktura łańcucha dostaw, tak przebieg procesu transportu może być ukształtowany. Postępująca globalizacja sprawiła, że zasięg łańcucha dostaw jest globalny, co powoduje, że struktura łańcucha jest wieloelementowa i skomplikowana. W takich układach dystrybucja towarów w miastach, która najczęściej jest na końcu tego łańcucha, jest bardziej zintegrowana z transportem dalekobieżnym. Dodatkowo występuje tendencja do skupiania się na potrzebach klienta indywidualnie, który niejednokrotnie jest również elementem łańcucha dostaw. Innym zjawiskiem jakie można zaobserwować, to dążenie podmiotów gospodarczych, które znajdują się w dolnej części łańcucha, do minimalizacji przestrzeni magazynowej, co powoduje konieczność częstego zamawiania towaru w małych ilościach. Wszystkie te zjawiska spowodowały, że praca przewozowa firm wzrosła, szczególnie w obszarach zurbanizowanych, co w konsekwencji przekłada się na negatywny wpływ transportu na otoczenie [104].

Dbałość o środowisko naturalne obecnie przestaje być modne i dobrowolne, lecz staje się to powoli obowiązkiem każdego człowieka, czy podmiotu gospodarczego. Jednym z trendów dbałości o środowisko naturalne jest ponowne wykorzystanie zużytych już zasobów. W systemie logistycznym przejawia się to w postaci przepływów wstecznych (rewersyjnych) materiałów, a dziedzina, która zajmuje się tą problematyką to logistyka zwrotna lub rewersyjna (ang. reverse logistics). Logistyka rewersyjna jest definiowana jako proces planowania, realizowania, kontrolowania przepływu „wstecz” strumieni surowców, zapasów, opakowań, zużytych wyrobów końcowych od punktu produkcji, dystrybucji lub końcowego użytkownika, do punktu odzysku, recyklingu lub właściwej utylizacji [34]. Należy nadmienić, iż w kręgu jej zainteresowań znajdują się tylko te strumienie materiałów lub produktów, z których istnieje potencjalna wartość do odzyskania i ponowna możliwość ich użycia. W celu podniesienia efektywności zbierania tego typu materiałów i ich późniejszego wykorzystania, coraz częściej w literaturze proponowane są rozwiązania, które łączą tradycyjną dystrybucję towarów z przepływami rewersyjnymi. Ograniczona pojemność pojazdów, specyfika przewożonych i zbieranych towarów, czas możliwości odbioru u klientów powoduje, że zadanie ułożenia tras przejazdu pojazdom jest bardziej skomplikowane. W rzeczywistości, obsługa transportowa takiego zbioru klientów jest wykonywana przez osobne pojazdy, co niepotrzebnie generuje koszty dla firm transportowych oraz koszty zewnętrzne transportu [104].

Dostępność i kongestia transportowa

Powyższa analiza dotyczyła sytuacji gdy świat zewnętrzny oraz otoczenie procesu transportowego wpływają na sam proces transportu oraz jakie związane są z tym problemy dla systemu logistycznego miasta. Sam proces transportu wpływa również na otoczenie i najczę-

ściej wpływa negatywnie. W badanych miastach europejskich, udział transportu dostawczego w całkowitym ruchu miejskim waha się od 20 do 30% [42]. Wyniki te mogą sugerować, że transport towarowy w mieście nie powinien mieć istotnego wpływu na funkcjonowanie miasta. Jednak jak wskazują analizy problemu [30, 97, 104, 132, 150, 151], że ten rodzaj transportu stwarza realne i poważne problemy. Oddziaływanie transportu towarowego w miastach przejawia się w szczególności kwestii (rysunek 2.2): dostępności transportowej, kongestii transportowej, degradacji środowiska naturalnego, bezpieczeństwa oraz kwestii wizerunkowych miasta.

Dostępność i kongestia transportowa to dwa zjawiska, z których jedno wynika z drugiego. Mianowicie brak dostępności transportowej dla miejskiego transportu towarów może być powodowany przez nieodpowiednią infrastrukturę drogową, ograniczenia dostępności (np. ograniczenie czasowe, wagowe, spełniania euro norm przez pojazdy) oraz przez kongestię. Dystrybucja towarów jest kluczowa dla poprawnego funkcjonowania miasta, jednak w wielu miastach infrastruktura transportowa nie jest odpowiednio dostosowana do potrzeb transportu. Istnieje poważny problem z dostępnością miejsc rozładunkowych pojazdów, a nawet, jeśli takie istnieją, często są nielegalnie zajmowane przez nieuprawnione pojazdy [97]. Skutkuje to parkowaniem przez pojazdy logistyki miejskiej na jezdniach lub miejscach gdzie pojazd ten generuje lokalne zatory i utrudnienia w ruchu (na rysunku 2.3 przedstawiono procentowy udział miejsc gdzie się odbywa rozładunek). Z drugiej strony zwiększanie (lub nieograniczanie) dostępności transportowej dla transportu towarowego, może znacząco wpływać na jakość życia mieszkańców i wizerunek miasta.

Wpływ na środowisko naturalne

Negatywnym wpływem dystrybucji towarów w mieście na środowisku naturalnym jest przede wszystkim emisja spalin i emisja hałasu, wibracje oraz zanieczyszczenie wód i gleby (poprzez wycieki płynów eksploatacyjnych). Jak już wspomniano udział transportu dostawczego w ruchu miejskim wynosi 20-30%, jednakże udział w emisji spalin przypisywany tej aktywności transportowej to od 16%, aż do 60% (w zależności od rozważanej spaliny) [42]. Dla przykładu w badaniach w 2006 roku w mieście Dijon (Francja) udział transportu towarowego wynosił około 26%. Udział emisji dla tego ruchu rozłożył się następująco: tlenek węgla (CO) - 20%, tlenki azotu (NO_x) - 36%, związki węglowodorów (HC) - 25% oraz cząstki stałe (PM10) - 60%. Głównym powodem takiego stanu rzeczy jest wiek pojazdów realizujących transport towarów⁹ oraz długość wykonywanej trasy przez pojazd i liczba zatrzymań pojazdu. Charakterystyka pracy rozwożenia towarów, wymaga częstego i ciągłego zatrzymywania się pojazdu w celu obsłużenia klientów, co znacznie wpływa na emisję spalin.


Oprócz zwiększonej emisji spalin, samochody ciężarowe emitują również więcej hałasu - zarówno podczas jazdy, jak również podczas postoju. Większy opór, jaki muszą pokonać samochody ciężarowe, potęguje natężenie emitowanego hałasu. Przykładowo hałaśliwość samochodu osobowego przy prędkości 50 km/h w odległości 7,5 metra od jezdni wynosi 60 – 80 dB, a samochodu ciężarowego w tych samych warunkach 80 – 95 d [132] B. Dla porównania dopuszczalny poziom hałasu w ciągu dnia na terenach śródmiejskich wynosi 65 dB¹⁰.

⁹ W Polsce w 2013 roku średnia wieku pojazdu powyżej 1500 kg ładowności wyniosła prawie 20 lat [63]

¹⁰ Rozporządzenie Ministra środowiska z dnia 14 czerwca 2007 (Dz.. U. 2007 r. nr 120 poz. 826 z 2007) r. w sprawie dopuszczalnych poziomów hałasu w środowisku

Bezpieczeństwo

Przewozy towarowe, jak wspomniano wcześniej, wpływają na bezpieczeństwo i płynność ruchu w mieście. Zwiększająca się liczba pojazdów ciężarowych i dostawczych, powoduje znaczący wzrost zapotrzebowania na powierzchnię dróg. Wynika to z faktu, że pojazdy ciężarowe zajmują nawet pięciokrotnie więcej powierzchni niż pojazdy osobowe. Co z kolei powoduje znaczny wzrost zatłoczenia na ulicach. Dodatkowo w większości miast rozładunek towarów odbywa się wprost na ulicach miasta, co wpływa na tworzenie się zatorów ulicznych. Potwierdzeniem tego stanu rzeczy mogą być badania w ramach projektu DORED, przeprowadzone w latach 2004-2010 na ponad 900 podmiotach gospodarczych działających na obszarach miejskich [90]. Wynika z nich (rysunek 2.3), że rozładunek w miejscach do tego wyznaczonych (zatorczka i zaplecze sklepu) odbywa się tylko w 20 % ankietowanych podmiotów. Pozostałe miejsca rozładunku to chodnik, jezdnia, bezpośrednio przed frontem obsługiwanego punktu lub jeszcze w innych niezdefiniowanych miejscach.



Rysunek 2.3 Deklarowane miejsca rozładunku (po lewej) oraz częstotliwość dostaw (po prawej)

Źródło: opracowanie własne na podstawie [90, 91].

Duże gabaryty pojazdów dostawczych zmniejszają widoczność kierowcom pojazdów osobowych, którzy mogą mieć przez to kłopoty z oceną sytuacji na drodze lub odpowiednio wczesne zauważenie znaków drogowych, czy sygnalizacji świetlnej. Również znacznie większa masa pojazdów dostawczych, w stosunku do samochodów osobowych, powodują szybsze zniszczenia infrastruktury drogowej. W tworzących się w ten sposób koleinach, podczas deszczu, jest bardziej prawdopodobne wystąpienie efektu aquaplaningu¹¹, co powoduje niekontrolowane poślizgi, czyli zmniejsza bezpieczeństwo dróg.


Innym czynnikiem charakterystycznym dla transportu dostawczego w mieście, jest reżim czasowy narzucony na kierowców lub system wynagrodzeń oparty na np. liczbie odwiedzonych klientów w jak najkrótszym czasie. Taki stan rzeczy może generować agresywne zachowanie kurierów, brak uwagi oraz naruszanie przepisów ruchu drogowego, co w konsekwencji prowadzi do zwiększenia ryzyka zaistnienia kolizji drogowej [104].

¹¹ Aquaplaning - jest to zjawisko występujące na mokrej nawierzchni, które objawia się utratą przyczepności powierzchni opony z powierzchnią drogi.


Wpływ na wizerunek miasta

W przypadku miast, które opierają swoją gospodarkę na turystyce, rekreacji oraz kulturze, transport towarowy może wpływać negatywnie na wizerunek miasta. Jak już wspomniano powyżej rozładunek pojazdu najczęściej występuje na jezdni bądź chodniku (rysunek 2.3) powodując utrudnienia w ruchu pieszym. Sytuacja tą wpływa również na ruch pieszych oraz na ich odbiór wizerunku miasta. Dodatkowy efekt negatywnej percepcji pojazdów logistyki miejskiej przez pieszych potęguje nieprzyjemny zapach spalin oraz hałas towarzyszący pracom rozładunkowym. W latach 2007-2008 w ramach działania 10.3 projektu CIVITAS CARAVEL przeprowadzono badania dotyczące dystrybucji towarów w centrum Krakowa. W ramach tego działania zbadano m.in. odbiór przez pieszych realizację transportu dostawczego w rejonie Starego Miasta Krakowa. Negatywna opinia pieszych o transporcie dostawczym jest wynikiem (rysunek 2.4): blokowania chodników przez pojazdy, konieczności omijania pojazdów oraz emisji hałasu (w sumie 83% ankietowanych). Dodatkowo ponad dwie trzecie pieszych uważa, że towarzyszący poziom hałasu jest średni lub wyższy. Badanie to pokazuje, że problem dystrybucji towarów szczególnie w turystycznych częściach miasta może zmniejszać pozytywne wrażenie o mieście (głównie wśród turystów).

Jak opisałbyś poziom hałasu generowanego przez samochody na Rynku Głównym w Krakowie?



Co najbardziej przeszkadza Panu/Pani w transporcie dostaw?



Rysunek 2.4 Częściowe wyniki ankiety programu CIVITAS CARAVEL w 2007 roku, dotyczące transportu towarów w odbiorze pieszych i mieszkańców centrum Krakowa.

Źródło: opracowanie własne na podstawie [32]

2.1.2 ZAGADNIENIE WYZNACZANIA TRAS POJAZDÓW JAKO ELEMENT ZARZĄDZANIA

Ujęcie procesu transportowego w koncepcji logistycznego systemu miasta, daje możliwość spojrzenia na prozaiczny problem rozwożenia towarów do klientów w zupełnie innym świetle. Koszt ekonomiczny firmy transportowej nie jest jedynym kosztem, jaki występuje w procesie realizacji transportu towarów. Jak przedstawiono w poprzednim podrozdziale, proces transportu towarów w mieście generuje również koszty ekologiczne, społeczne oraz tzw. koszty zewnętrzne transportu. Skomplikowany system logistyczny miasta, gdzie występuje szereg elementów i uczestników wzajemnie oddziałujących na siebie, jest generatorem dużej liczby problemów. Ostatnie lata pokazują duże zainteresowanie aspektami poprawy efektywności dystrybucji towarów w miastach, szczególnie przez władze miast, państw a nawet odpowiednich jednostek administracji Unii Europejskiej. Przykładem takich działań są liczne projekty badawcze, których celem zazwyczaj jest zbadanie problemu, określenie miar efektywności, stworzenie zbioru dobrych praktyk w zarządzaniu towarowym transportem na obszarach miejskich oraz wskazanie rekomendacji. Zbiór dobrych praktyk jest tworzony w odniesieniu do przedsięwzięć różnych miast z całego świata, gdzie odbyły się lub wdrażane są obecnie pomysły na lepsze i efektywniejsze zarządzanie przepływami towarów w miastach [29, 30, 62, 97]. W związku tym, że nie jest celem pracy omawianie obecnie rekomendowanych strategii zarządzania ruchem towarowym w miastach, autor ograniczył swoją analizę tylko do elementów związanych z tematyką wyznaczania tras pojazdów.


W Unii Europejskiej jednostką administracyjną odpowiedzialną za efektywny rozwój transportu jest Wydział Mobilności i Transportu (ang. DG Mobility and Transport). W 2012 roku został wydany raport przez wspomniany podmiot, który jest syntetycznym opisem dotychczasowych osiągnięć w zakresie zarządzania transportem towarowym w logistyce miejskiej, jak również zbiorem rekomendacji dobrych praktyk [97]. Podobny raport powstał również w Stanach Zjednoczonych, opublikowany w 2013 roku, którego cel był tożsamy z europejskim dokumentem [62]. Mając na uwadze problematykę wyznaczania tras pojazdów należałoby zwrócić uwagę na cztery rekomendacje obu raportów, które dotyczą poprawy jakości transportu towarów w miastach. Są to:

1. budowa Miejskich Centrów Konsolidacji (ang. Urban Consolidation Centre),
2. wdrażania technologii z zakresu Inteligentnych Systemów Transportowych,
3. "rozwiązania ostatniego kilometra"¹²,
4. zaplanowanie tras pojazdów ciężarowym, których cel/źródło podróży znajduje się na obszarach miejskich.

Idea Miejskich Centrów Konsolidacji (dalej MCK) jest oparta na koncepcji koncentracji przepływów towarów w jednym punkcie oraz na odpowiedniej konsolidacji tych przepływów. Zgodnie z projektem BESTUFS, definicja MCK brzmi następująco: "jest to baza logistyczna, umiejscowiona blisko miejsca świadczenia usług (np. centrum miasta, całe miasto lub konkretna lokalizacja, jak np. centrum handlowe), do którego wiele przedsiębiorstw dostarcza towary przeznaczone dla obsługiwanego obszaru, z którego realizowane są skonsolidowane

¹² "Rozwiązania ostatniego kilometra" są logistycznym elementem procesu w ramach to dostawy towarów do indywidualnych klientów w transakcjach e-handlu, realizacji zamówień pocztowych, sprzedaży bezpośredniej oraz dostaw do punktów sprzedaży detalicznej [30].

dostawy oraz w ramach, którego mogą być realizowane dodatkowe usługi logistyczne i detaliczne" [30]. Ilustracja powyższej definicji przedstawia rysunek 2.5.



Rysunek 2.5 Zasada działania miejskiego centrum konsolidacyjnego.

Źródło: opracowanie własne.

Głównym celem MCK jest świadczenie usług transportowych dla tego samego zbioru klientów, wykorzystując zredukowaną liczbę pojazdów, czego efektem będzie przede wszystkim zysk ekologiczny i społeczny¹³. Redukcja wykorzystywanych pojazdów jest uzyskiwana przez konsolidację przepływów towarów oraz przez wykorzystanie zaawansowanych metod optymalizacji marszrutyzacji tras pojazdów MCK [30, 62, 97].

Właściwe wykonanie optymalizacji obsługi transportowej klientów wymaga posiadania odpowiedniej, rzeczywistej informacji o ruchu, zdarzeniach drogowych czy aktualnym wykorzystaniu obiektów infrastruktury, np. zajętość zatoczek rozładunkowych pojazdów logistyki miejskiej. Tego typu informacje są możliwe do uzyskania m.in. dzięki narzędziom ITS. Wdrażanie ITS do systemu miasta we wspomnianych raportach jest wskazywane, jako podstawowe i bardzo ważne rozwiązanie, które w bezpośredni sposób może się przyczynić do efektywniejszego i ekologicznego wykorzystania posiadanych zasobów. Źródłem informacji przydatnych w planowaniu i realizacji transportu towarów mogą być: urządzenia automatycznej lokalizacji pojazdu (ang. Automatic Vehicle Location), urządzenia automatycznego pomiaru parametrów pojazdu (ang. Automatic Vehicle Monitoring), system GSM/GPRS, systemy informacji geograficznej (ang. Geographical Information System), system identyfikacji radiowej (ang. Radio Frequency Identification - RFID) oraz urządzenia do pomiaru paramet-

¹³ Na podstawie doświadczeń zachodnich miast Europy, MCK nie przynoszą zysków finansowych, co więcej poprawne ich funkcjonowanie wymaga stałego wspierania przez lokalne władze. Jest to największa wada tego rozwiązania, jednakże ponoszony koszt finansowy można było zrekompensować zyskami ekologicznymi. Dla przykładu w Londynie w 2006 roku zostało stworzone Budowlane Centrum Konsolidacyjne, które miało zaopatrzać w materiały budowlane największe budowy w mieście. Efektem działania było: 68% redukcja liczby używanych pojazdów, 75% redukcji emisji spalin, 15% redukcji strat w używanych materiałach budowlanych, średnio o 2 godziny skrócił się czas dostawy oraz średnio o 30 min dziennie została przyspieszona produktywność budowy. Niestety po ponad trzech latach działania centrum logistyczne zostało ono zamknięte przez przynieszone straty finansowe. Po mimo tych faktów, w 2013 w Europie funkcjonowało ok. 150 obiektów logistycznych pełniących funkcje na kształt MCK.

trów ruchu tj. detektory, video-detektory, czy też dane z technologii Floating Car Data¹⁴. Wykorzystanie tych informacji, zgodnie z zaleceniami raportów, powinno być łatwo dostępne dla podmiotów zainteresowanych, głównie świadczących usługi transportowe w miastach [97]. Utworzona w ten sposób platforma informacji o ruchu drogowym powinna być wykorzystana przez firmy transportowe do wykonywania optymalizacji tras pojazdów, w celu efektywniejszej obsługi transportowej miasta.

Ostatnie dwie rekomendacje, czyli "rozwiązania ostatniego kilometra" oraz planowanie przebiegu tras pojazdów ciężarowych, których cel/źródło podróży znajduje się na obszarach miejskich, również zakładają możliwość wykorzystania metod optymalizacyjnych przy wyznaczaniu tras. Analogicznie jak w przypadku MCK, zakłada się że dostęp do niezbędnych informacji będzie pozyskany z technologii ITS dzięki odpowiednim platformom wymiany informacji

2.2 PROBLEMATYKA WYZNACZANIA TRAS POJAZDÓW

Problematyka układania trasy pojazdowi jest problemem podejmowanym w literaturze już od XIX wieku, gdzie pierwszą definicję zagadnienia przedstawił W.R. Hamilton w 1859 roku. Zagadnie to do dzisiaj nosi nazwę problemu komiwojażera (ang. Traveling Salesman Problem - dalej TSP). Problem ten można przedstawić następująco: sprzedawca pewnego przedsiębiorstwa wyrusza w podróż by odwiedzić swoich znanych klientów; sekwencja odwiedzania klientów jest dowolna, jednak przy zachowaniu warunków, że każdy klient musi być odwiedzony tylko raz, sprzedawca na koniec musi powrócić do firmy oraz całkowita długość trasy ma być najkrótsza [72]. Problemy klasy TSP mają charakter kombinatoryczny i należą do klasy problemów NP - trudnych¹⁵ [94].

Uogólnieniem problemu TSP jest zagadnienie wyznaczania tras flocie pojazdów, którego celem jest odnalezienie optymalnej trasy dla dowolnej liczby pojazdów (pojazd jest tutaj analogią do sprzedawcy). W polskiej literaturze problem ten znany jest również pod pojęciami: problem marszrutyzacji pojazdów, zagadnienie układania tras pojazdom, problem trasowania pojazdów lub zagadnienie wyznaczania planów przewozów. Zadanie VRP po raz pierwszy zostało sformułowane w 1959 roku przez Dantzig'a i Ramser'a [43] jako problem rozdziału pojazdów (ang. truck dispatching problem), a pierwszy matematyczny model tego problemu sformułowany przy pomocy programowania liniowego został przedstawiony w 1964 roku [16]. Na popularność i ważność tej problematyki w dalszych latach może wskazywać liczba publikacji, jaka powstała w przeciągu 50 lat - w bazach danych Scopus można odnaleźć ponad 4000 prac naukowych dotyczących tej tematyki [119].

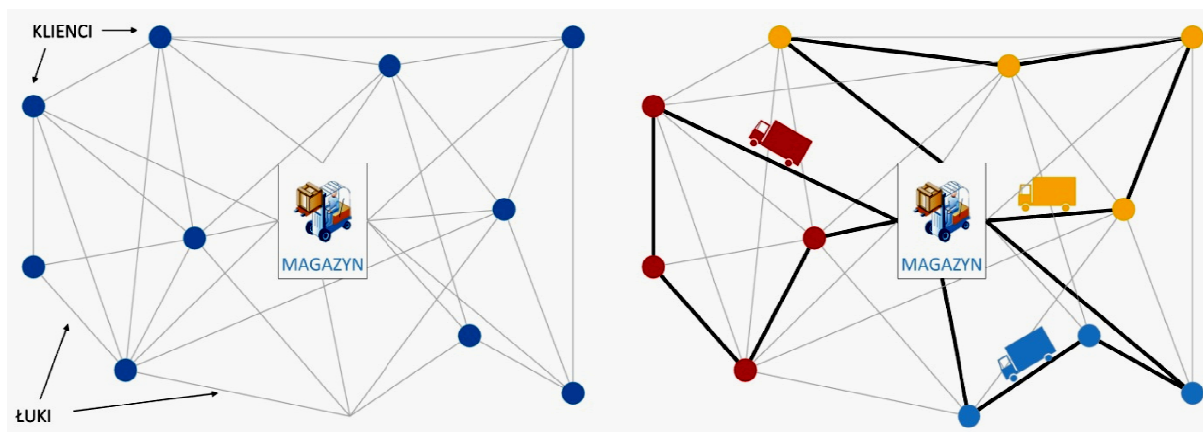
Dystrybucja towarów w tym zagadnieniu polega na świadczeniu usług transportowych klientom poprzez rozwożenie towarów zgodnie z ich zgłoszonym zapotrzebowaniem - tak

¹⁴ Technologia uzyskująca informacje o średniej prędkości czasie przejazdu na danych odcinkach na podstawie anonimowych informacji z urządzeń GPS lub GSM.

¹⁵ Problem klasy NP - trudnej oznacza, że poziom pracochłonności w celu wyznaczenia optymalnego rozwiązania rośnie wykładniczo wraz z rozmiarem problemu. Dla przykładu, jeśli komiwojażer ma do odwiedzenia 10 klientów, a koszty między nimi nie są symetryczne, to liczba możliwych konfiguracji sekwencji odwiedzania klientów wyniesie ponad 3,6 miliona tras.

zwanym popytem na towary. Usługi transportowe są realizowane przez flotę pojazdów, które poruszają się po sieci drogowej oraz rozpoczynają i kończą swoje trasy w bazie zwanej magazynem. Celem zadania VRP jest odnalezienie trasy dla każdego pojazdu tak, aby całkowity koszt, zazwyczaj dystans, był najmniejszy. W dalszej części podrozdziału zostanie przedstawiona charakterystyka pozostałych głównych komponentów ogólnego modelu matematycznego VRP [145] oraz krótki przegląd klas problemów VRP.

Sieć drogowa, po której poruszają się pojazdy zazwyczaj jest przedstawiana jako graf, którego wierzchołki reprezentują skrzyżowania, a połączenia pomiędzy wierzchołkami grafu są zdefiniowane przez zbiór skierowanych łuków. Każdy łuk grafu może mieć przypisane koszty: zazwyczaj długość oraz czas przejazdu, który może być różny dla danego typu pojazdu, czy też danego okresu czasu, np. w zależności od pory dnia. W klasycznej odmianie problemu VRP klienci są przypisywani do wierzchołków grafu, a każdy klient charakteryzuje się popytem na towary. W zależności od specyfiki analizowanego problemu klientom można przypisać różne cechy, np. okno czasowe obsługi, które oznacza przedział czasowy, w jakim dany klient preferuje, aby usługa transportowa została zrealizowana, czy też średni czas obsługi klienta. Czas obsługi może być również funkcją wagi przewożonego towaru. Poglądową reprezentację modelu VRP w postaci grafu oraz jego przykładowe rozwiązanie przedstawia rysunek 2.6.



Rysunek 2.6 Przykład problemu VRP w postaci grafu (po lewej) oraz jego rozwiązanie (po prawej).

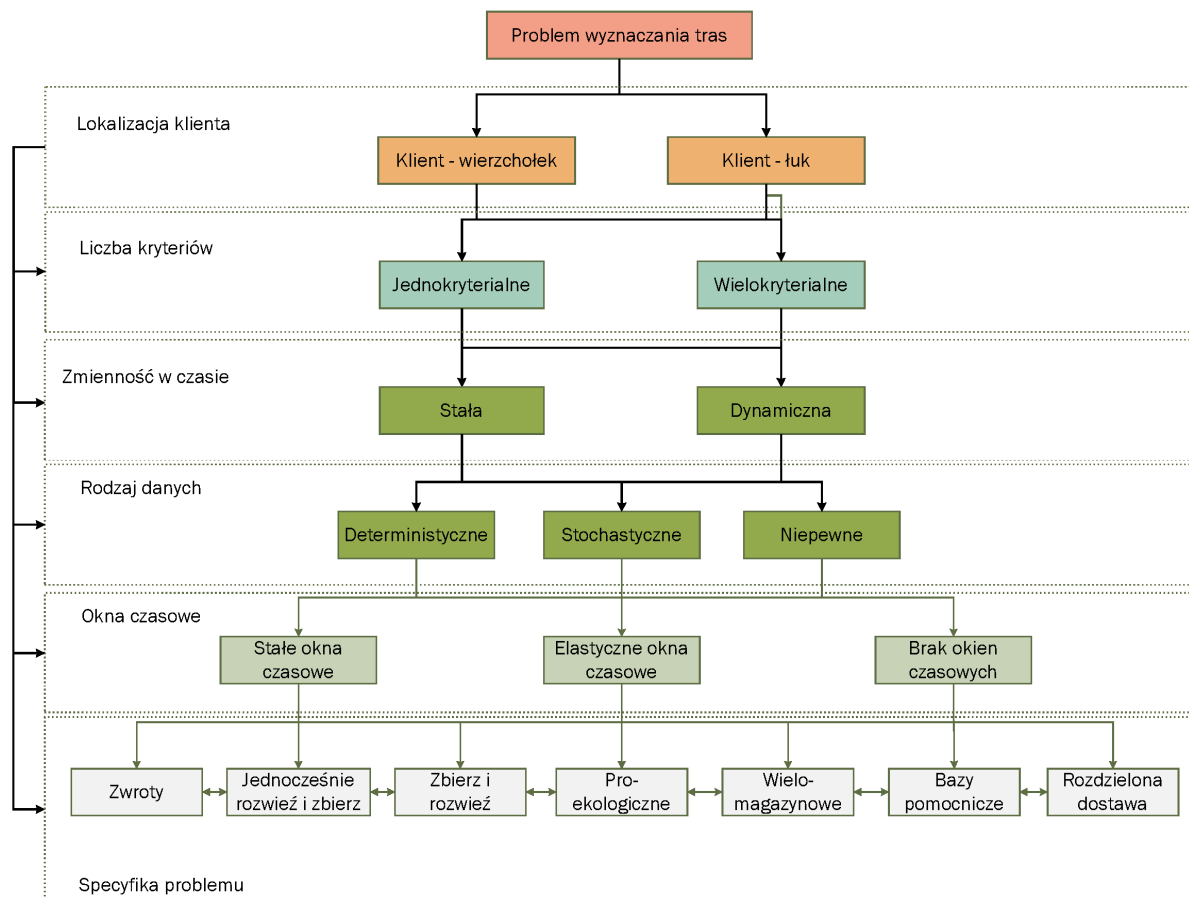
Źródło: opracowanie własne.

Magazyn modelu VRP w rzeczywistości może odpowiadać bazie logistycznej firmy transportowej, magazynu czy też centrum logistycznemu, gdzie znajdują się towary przygotowane do rozwiezienia klientom oraz flota pojazdów. Towary są wyrażane na ogół w jednostkach masy, jednostkach ładunkowych np. palety, jednostkach objętości towaru lub kombinacji poprzednich. Pojazdy mogą być homogeniczne bądź heterogeniczne biorąc pod uwagę ich maksymalną ładowność. W rzeczywistości firmy transportowe dysponują różnorodną flotą, wobec czego koszty operacyjne każdej kategorii pojazdów są różne. Przy modelowaniu matematycznym różnorodność pojazdów, ograniczenia ekologiczne lub dotyczące maksymalnej dopuszczalnej masy całkowitej pojazdu, jakie władze miast nakładają na niektóre obszary miasta, dla każdego typu pojazdu, można uwzględniać przez stosowanie różnych kosztów podróży oraz różnych zbiorów połączeń pomiędzy skrzyżowaniami. Na przykład, odcinkom sieci drogowej znajdujących się w centrum miasta można nadać mniejsze koszty przejazdu

takimi odcinkami pojazdów o mniejszych rozmiarach i spełniających wyższe normy ekologiczne, niż pojazdów o większych rozmiarach lub można w ogóle wyeliminować te odcinki ze zbioru incydencji. Dzięki takim metodom model matematyczny będzie dokładniej opisywać rzeczywistość.

Kolejnym elementem modeli VRP są kierowcy i związane z nimi wymagania. Głównym ograniczeniem, wynikającym z ustawy o czasie pracy kierowców, to maksymalny czas pracy kierowcy pojazdu oraz wymagane przerwy w czasie pracy. W modelu matematycznym realizowane jest to za pomocą dodatkowych ograniczeń na czas trwania całej trasy.

Wszystkie wymienione powyżej kwestie oraz te, które licznie występują w literaturze przedmiotu¹⁶, spowodowały, że ponad pół wieku rozważań nad problematyką wyznaczania tras pojazdom stworzyło całą rodzinę różnorodnych modeli matematycznych oraz metod ich rozwiązywania. Na rysunku 2.7 przedstawiono zagregowany schemat odmian zagadnień VRP wraz z ich podziałem na główne klasy (na podstawie: [14, 25, 33, 43, 46, 50, 51, 54, 64, 69, 74, 77, 84, 85, 87-89, 93, 100, 110, 114, 120, 124, 134, 138, 142, 145, 147]).



Rysunek 2.7 Zagregowany schemat odmian zagadnień VRP wraz z ich podziałem na główne klasy

Źródło: opracowanie własne na podstawie: [14, 25, 33, 43, 46, 50, 51, 54, 64, 69, 74, 77, 84, 85, 87-89, 93, 100, 110, 114, 120, 124, 134, 138, 142, 145, 147].

Na schemacie zaprezentowano tylko hasła kluczowe, z których połączenie (zgodnie z strzałkami) może stworzyć konkretny przypadek VRP. Dla przykładu idąc kolejno: Problem

¹⁶ W związku z tym, że celem pracy nie jest przedstawienie rodziny odmian VRP, autor ograniczył się tylko do poglądowej analizy tej problematyki.

wyznaczania tras -> Klient-wierzchołek -> Wielokryterialne -> Stałe ->Deterministyczne -> Okna czasowe -> Zbierz i Rozwiń, przestawi odmianę wielokryterialnego problemu wyznaczania tras z w pierwszej kolejności zbieraniem towarów, a kolejne z rozwożeniem tych towarów w oparciu o koszty deterministyczne z uwzględnieniem okien czasowych (ang. Multicriteria Pick-up and Delivery Routing Problem with Time Windows). Dodatkowe strzałki pomiędzy kolejnymi grupami oraz pomiędzy odmianami w klasie "Specyfika problemu" przedstawiają dodatkowe możliwości utworzenia kolejnych problemów z rodziny VRP. Różnorodność tych grup jest wynikiem odzwierciedlenia przez naukowców heterogeniczności specyfiki rzeczywistych problemów transportowych.

Zaprezentowana skrótość haseł jest wynikiem intencji autora do zachowania przejrzystości i czytelności schematu. Zdecydowana większość prac dotycząca problematyki VRP jest w języku angielskim, który jest bardziej zwięzły niż język polski, wobec czego zastosowano propozycję tłumaczenia autora w formie krótkich haseł¹⁷.

Przedstawiony schemat nie wyczerpuje szerokiej tematyki wyznaczania tras pojazdom, prezentuje on prawdopodobnie najbardziej popularne odmiany VRP. Istnieją również dwa podejścia do modelowania problemu VRP korzystając z teorii grafów: w pierwszym zakłada się, że klienci są przypisani do wierzchołków grafu: "Klient - wierzchołek" (ang. Node Routing Problem), a w drugim przyjmuje się, że klienci są przypisani do łuków grafu "Klient - łuk" (ang. Arc Routing Problem). Jednakże modele matematyczne "Klient - łuk" są zdecydowanie bardziej złożone obliczeniowo, stąd też popularność ich w literaturze przedmiotu oraz aplikacyjna stosowalność w rzeczywistości jest zdecydowanie mniejsza. Można odnieść wrażenie, że drugie podejście jest właściwsze, bardziej zbliżone do rzeczywistości, bo zakłada występowanie klienta na łuku. Jednak w podejściu "Klient - wierzchołek" można dodać dodatkowe wierzchołki w grafie, które podzielą dany odcinek grafu na dwie części, dzięki czemu również w tym modelu matematycznym uzyska się efekt, że klienci będą znajdować się wzdłuż drogi. Metoda ta, niestety może mieć wpływ na czas obliczeń (rośnie liczba możliwych permutacji sekwencji klientów).

Kolejną klasą VRP, rozważaną w analizach naukowych, jest kwestia liczby przyjętych kryteriów uwzględnionych w procesie optymalizacji problemu. Z uwagi na fakt łatwości modelowania matematycznego i czasu obliczeń komputerowych, najpopularniejsze są modele jednokryterialne (ang. Single Criterion). Najczęściej stosowane kryteria to:

- minimalizacja łącznego czasu pracy wszystkich użytych pojazdów (w dalszej części pracy będzie ono równoważne z pojęciem czasu operacyjnego pojazdów),
- minimalizacja łącznego pokonanego dystansu przez użytą flotę (w dalszej części kryterium to będzie utożsamione z pracą przewozową),
- minimalizacja liczby użytych pojazdów do obsługi danego zbioru klientów,
- maksymalizacja poziomu wykorzystania ładowności pojazdów,
- maksymalizacja poziomu obsługi klientów - poziom obsługi klienta może być wyrażony przy pomocy jednostki czasu, która będzie określać czy dany pojazd przyjechał do klienta zbyt wcześnie, w preferowanym oknie czasowym, czy też rozpoczął obsługę po czasie;

¹⁷ Tłumaczenia te nie są ogólnie funkcjonującymi terminami w polskiej literaturze przedmiotu, są propozycją autora.

- minimalizacja zużycia paliwa przez pojazdy,
- minimalizacja kosztu emisji CO₂ - na podstawie charakterystyk emisyjnych pojazdów można obliczyć potencjalny koszt jaki jest związany z obsługą transportową danego obszaru przez użyte pojazdy,
- minimalizacja kosztu czasu pracy kierowcy,

Problemy VRP wielokryterialne (ang. Multi-criteria/ Multi-Attributive Vehicle Routing Problem) zakładają w modelu matematycznym, że celem optymalizacji jest uwzględnienie przynajmniej dwóch kryteriów.

Rodzaj danych jest kolejnym ważnym komponentem problematyki VRP, który tworzy kolejną grupę. W głównej mierze dane wykorzystywane w problematyce układania tras pojazdom dotyczą kosztów przypisanych do łuków sieci drogowej, np. długość odcinka, czas przejazdu danego odcinka. Inne dane to wielkość popytu/podaży klientów, czy też okna czasowe u klientów. W zależności od zmienności w czasie dane te można podzielić na dwie grupy:

- stałe - wartości danych modelu nie zależą od jednostki czasu. Przyjmuje się, że specyfika danych np. wartość średnia, odchylenie standardowe, itp. nie zmienia swojej wartości w horyzoncie planowania,
- dynamiczne - wartości danych modelu zależą od jednostki czasu w postaci dyskretyzowanej, w postaci interwałów (ang. Vehicle Routing Problem with Interval Data) lub w sposób ciągły, w postaci funkcji od czasu (ang. Dynamic/Real-Time Vehicle Routing Problem);

Rodzaj danych zastosowany w modelu również tworzy osobne grupy zagadnienia wyznaczania tras pojazdom i takie zagadnienie może być:

- deterministyczne - dokładne wartości znane z góry; grupa deterministycznych problemów VRP (ang. Deterministic Vehicle Routing Problem),
- stochastyczne - wartości danych nie są znane dokładnie, są losowe; zakłada się że zmienność jest opisana rozkładem prawdopodobieństwa, który jest z góry znany; grupa stochastycznych problemów VRP (ang. Stochastic Vehicle Routing Problem),
- niepewne - tak jak w przypadku danych stochastycznych, dane modelu nie są dokładnie znane i są przyjmowane z pewnym poziomem niepewności. Niepewność może być związana np. z błędem metody pomiaru lub z błędem metody prognozy. Przeciwnie niż w modelach stochastycznych nie zakłada się znajomości rozkładu prawdopodobieństwa w oparciu, o który realizowany jest brak precyzji danych modelu. W odniesieniu do problemów VRP, w których uwzględniono taką niepewność wykorzystywana jest teoria optymalizacji odpornej - grupa odpornych na wahania parametrów modelu problemów VRP (ang. Robust Vehicle Routing Problem).

Kolejna istotna grupa VRP została utworzona przez fakt występowania okien czasowych u klientów. Grupa "Brak okien czasowych" oznacza klasę problemów VRP gdzie klienci nie mają preferencji, co do czasu rozpoczęcia obsługi. Jak już wspomniano, okno czasowe, to interwał czasowy, w którym klient preferuje, aby towar został dostarczony. W rzeczywistości, okna czasowe są realizowane na dwa sposoby: poprzez świadomy wybór klienta bądź też narzucony z góry przez przewoźnika. W obu przypadkach, klient powinien być obsłużony w wyznaczonym oknie, w przeciwnym wypadku, firma transportowa może ponieść dodatko-

we koszty. Poniesiony koszt spowodowany np. zbyt późnym przyjazdem do klienta, może stworzyć dwie sytuacje:

- klientowi zostanie dostarczony towar, jednak poziom zadowolenia z usług transportowych będzie niższy niż gdyby pojazd byłby w uzgodnionym czasie. Założenie to tworzy grupę "Elastyczne okna czasowe" (ang. Vehicle Routing Problem with Flexible/Soft Time Windows); inne pojęcie funkcjonujące w literaturze przedmiotu to "elastyczne okna czasowe",
- klient nie przyjmie towaru - koszt utraty klienta oraz przyjazdu pojazdu i kierowcy. Obsługa jest możliwa tylko i wyłącznie w wyznaczonym oknie - wcześniejsza lub późniejsza obsługa jest nie możliwa. Tworzy to grupę "Stałe okna czasowe" (ang. Vehicle Routing Problem with Hard Time Windows); inne pojęcie funkcjonujące w literaturze przedmiotu to "twarde okna czasowe",

Ostatni element przedstawiony na powyższym schemacie to "Specyfika problemu", czyli przyjęcie założeń w modelu matematycznym VRP, które odnoszą się do konkretnych wymagań i cech rzeczywistego obiektu. Można tu wyszczególnić:

- "Zwroty" (ang. Vehicle Routing Problem with Backhauls) - klient po dostarczeniu towaru może go od razu zwrócić,
- "Jednocześnie rozwiąż i zbierz" (ang. Vehicle Routing Problem with Simultaneous Pickup and Delivery) - klient może cechować się popytem i podażą na towary, a pojazd realizujący trasę musi w ramach jednej wizyty rozwozić towary do danego klienta i ewentualnie od niego odbierać inne. W literaturze zagranicznej jest to również znane pod pojęciem zagadnienia wyznaczania tras pojazdom z uwzględnieniem aspektów logistyki rewersyjnej (ang. Reverse Vehicle Routing Problem),
- "Zbierz i rozwiąż" (ang. Vehicle Routing Problem with Pickup and Delivery) - część klientów może charakteryzować się popytem, a pozostała część podażą na towary; zadaniem pojazdu (kierowcy) jest w pierwszej kolejności odebranie towarów od klientów, w następnie rozwiązanie tych towarów do docelowych klientów,
- "Pro-ekologiczne" (ang. Green/Pollutant Vehicle Routing Problem) - głównym celem tej klasy problemów jest wyznaczenie tras pojazdom przy uzyskaniu minimalnego negatywnego oddziaływania pojazdów na środowisko naturalne,
- "Wielo-magazynowe" (ang. Multi-depot Vehicle Routing Problem) - zakłada się, że towary są zlokalizowane w kilku magazynach, a dostawy do klientów mogą być zrealizowane z dowolnego magazynu, przy czym jeden klient może być obsługany tylko przez jeden magazyn,
- "Bazy pomocnicze" (ang. Vehicle Routing Problem with Satellite Facilities) - w modelu występują dodatkowe obiekty tzw. satelity, które pełnią rolę pomocniczych (dodatkowych) magazynów. W trakcie realizacji trasy pojazd może uzupełnić braki towaru w takim magazynie, bez konieczności powrotu do bazy pierwotnej. Taka sytuacja w rzeczywistości odpowiada dystrybucji paliw i niektórych produktów detalicznych,
- "Rozdzielona dostawa" (ang. Split Delivery Vehicle Routing Problem) - inaczej niż w klasycznych założeniach VRP, dany klient może być obsługany przez więcej niż jeden pojazd (najczęściej stosowany, gdy popyt danego klienta jest większy niż dostępna ładowność pojazdów).

Jak wynika z przeprowadzonego pogładowego przeglądu, zakres problematyki wyznaczania tras pojazdów jest bardzo szeroki i zróżnicowany. Jednakże poszukując prac, które rozważałyby kwestię występowania niepewności zjawisk, jak również niepewności posiadanych danych, można trafić na niewielką liczbę pozycji. Szczególnie jest to widoczne w przypadku niepewności wartości danych, których zmienność nie jest opisana rozkładem prawdopodobieństwa. Szczegółowy opis tych publikacji zawarto w następnym rozdziale po uprzednim przedstawieniu problematyki niepewności danych w systemie transportowym miasta oraz po wprowadzeniu podstawowych pojęć związanych z modelowaniem niepewności w matematycznych modelach.

2.3 PROBLEM WYZNACZANIA TRAS POJAZDÓW W UJĘCIU SYSTEMOWYM

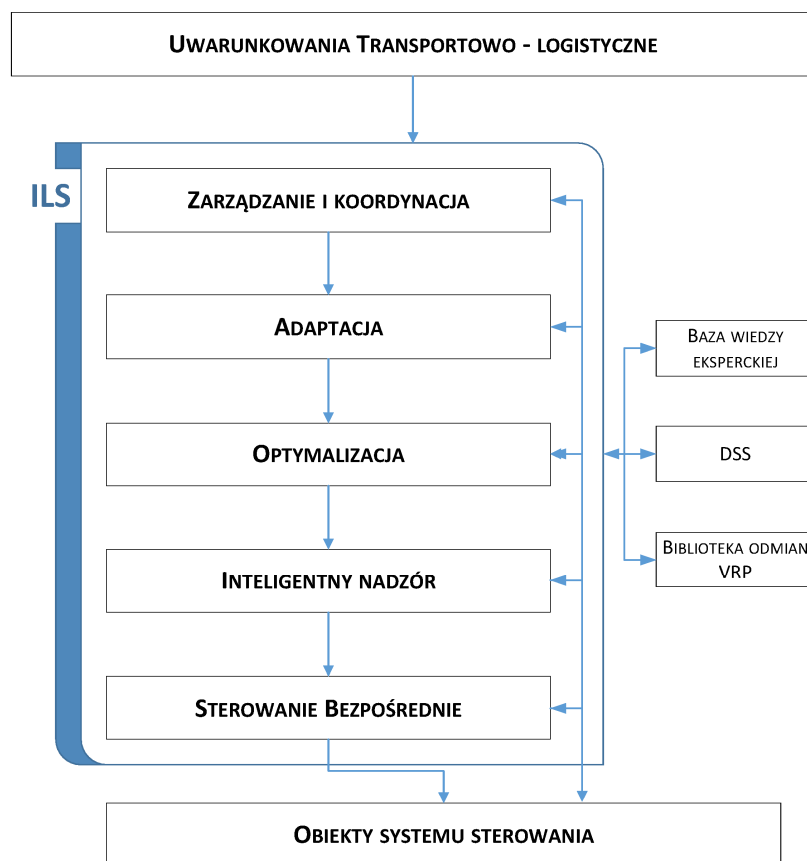
Poruszana tematyka dotyczy zagadnień związanych z realizowaniem obsługi klientów, którzy zgłaszają swoje zapotrzebowanie na usługi transportowe. Celem właściwego planowania jest minimalizacja kosztów (czas, dystans) związanych z realizacją tras oraz maksymalizacja poziomu świadczonych usług transportowych. Zaprezentowana, w kolejnych rozdziałach, metoda optymalizacji tras przewozu ładunków w mieście w warunkach niepewności, może posłużyć jako narzędzie do wspomagania decyzji w ramach takiego procesu planistycznego. Jednakże sam proces planowania i realizacji, czy też właściwej optymalizacji, nie jest hermetycznym elementem systemu transportowo - logistycznego, szczególnie miasta. Na specyfikację optymalizacji wpływa otoczenie transportowe, jak i realizacja rozwożenia towarów wpływa na system transportowy - występują bowiem sprzężenia zwrotne w relacjach. Z tego względu rozpatrywanie problematyki planowania tras pojazdów powinno być rozpatrzone w ujęciu szerszym - systemu transportowego i logistycznego miasta. W poprzednich podrozdziałach dokonano analizy systemu transportowego miasta w aspekcie logistycznym, jednak rozważania te ograniczały się tylko do identyfikacji relacji pomiędzy uczestnikami oraz określenia problemów jakie te relacje generują.

Synteza wniosków głównie dotyczyła zagadnień związanych z poruszaniem się pojazdów logistyki miejskiej realizujących transport towarów oraz obecnie rekomendowanych metod zarządzania tymi pojazdami. Proponowana metodyka jest jednym ze sposobów właściwego, bardziej rzeczywistego podejścia do zagadnienia planowania transportu w mieście. Jednakże, podejście to bazuje na jednym głównym założeniu - w trakcie procesu planowania decydent posiada dostęp do dużej ilości reprezentatywnych danych charakteryzujących analizowany obszar miasta. Są to przede wszystkim dane dotyczące historycznych i aktualnych parametrów ruchu. Posiadanie tych informacji jest szczególnie istotne, ponieważ właściwa optymalizacja bazuje na danych, od jakości których zależy wynik i efektywność działania całego systemu transportowego. Obecny postęp usług ITS oraz technologii teleinformatycznych nie stoi na przeszkodzie, aby takie dane pozyskać. Problem może się pojawić, gdy dane przedsiębiorstwo transportowe będzie dysponować takimi informacjami, a nie będzie mogło ich optymalnie i właściwie wykorzystać. Rozwiązaniem tego typu problemów jest odpowiednie zaprojektowanie relacji występujących pomiędzy dostępnym zbiorem: narzędzi, usług informatycznych, metod zarządzania, metod optymalizacji procesów oraz urządzeń pomiarowych.

W literaturze przedmiotu dotyczącej problemów VRP głównie można spotkać prace i badania w kierunku: bardziej dokładnego zdefiniowania problemu w postaci modeli matematycznych; propozycji, co raz to lepszych metod optymalizacyjnych lub analizy studiów przypadku. Inny sposób spojrzenia na tego typu problem, to podejście systemowe przez umiejscowienie zagadnień VRP w logistycznym systemie miasta i odniesienie ich do aktywności inteligentnych systemów transportowych, którą można odnaleźć w pracach [2, 5] oraz w artykułach [6, 7], których autor pracy jest współtwórcą. W pracach tych zaprezentowana jest koncepcja Inteligentnych Systemów Logistycznych [3] (ang. Intelligent Logistics Systems - dalej ILS), które swoją strukturę konceptualną opiera również o kooperację z architekturą ITS. Podstawowym założeniem idei architektury ILS jest integracja wertykalna i horyzontalna wszystkich warstw składowych systemu, które pełnią określone funkcje. W europejskim projekcie FRAME [59], nie występują warstwy, a integracja dotyczy tzw. funkcjonalności, która każda z nich ma za zadanie realizować oczekiwania użytkowników systemu transportowego. W inny sposób koncepcja ILS ma kooperatywnie realizować potrzeby użytkowników systemu miasta, ale w kontekście logistycznym. Głównym celem koncepcji ILS (podobnie jak ITS) jest inteligentne wykorzystanie posiadanej informacji, przy użyciu zaawansowanych narzędzi i metod. Obecnie jest zauważalna tendencja do wdrażania pojedynczych rozwiązań, technologii i usług dotyczących transportu i procesów logistycznych, jednak ogrom otrzymanych informacji nie jest we właściwy sposób połączony (zintegrowany) i we właściwy sposób wykorzystany przez użytkowników (inteligencja).

System logistyczny oraz występujące w nim procesy można podzielić na pięć funkcjonalnych komponentów - hierarchicznych, zintegrowanych warstw w koncepcji ILS. Podział ten jest wynikiem naturalnego wyodrębnienia pełnionych funkcji przez poszczególne warstwy systemu w ramach aktywności miejskiej (rysunek 2.8). Podejście to zakłada występowanie (w kolejności od góry do dołu) [2]:

1. Warstwy Zarządzania i Koordynowania (ang. Management and Coordination Layer),
2. Warstwy Adaptacji (ang. Adaptation Layer),
3. Warstwy Optymalizacji (ang. Optimisation Layer),
4. Warstwy Monitoringu i Inteligentnego Nadzoru (ang. Supervision Layer),
5. Warstwy Bezpośredniego Sterowania (ang. Control Layer).



Rysunek 2.8 Koncepcja Inteligentnych Systemów Logistycznych ILS w kontekście zagadnień wyznaczania tras pojazdów.

Źródło: opracowanie własne na podstawie:[1,6].

Najwyższa warstwa podejścia - zarządzania i koordynacji, to wszystkie działania zarządcze mające na celu skoordynowanie przepływu towarów, informacji oraz danych w obszarach produkcji, dystrybucji, magazynowania oraz transportu towarów przewidzianych dla klientów. W obrębie tej warstwy występują m.in. systemy do zarządzania informacją (np. typu ERP), relacjami z klientami, zarządzania łańcuchem dostaw, systemy informatyczne do zarządzania magazynem oraz wszelkie systemy wspomagające decyzje logistyczne. Idea tej warstwy to: integracja informacji, dotyczącej przemieszczania towarów w mieście, np. zgłaszanego popytu i podaży na usługi transportowe, charakterystyki wymagań klientów, celów strategicznych firmy transportowej, celów polityki transportowej miast w zakresie logistyki miejskiej, itp. oraz właściwe wykorzystanie tej informacji. Celem funkcjonowania warstwy zarządzania i koordynacji jest wskazywanie optymalnych kierunków działań w zakresie przepływu towarów opierając je o wielokryterialne metody podejmowania decyzji oraz inteligentne narzędzia wspomagania decyzji (ang. Decision Support System - dalej DSS). Kryteria poszukiwania rozwiązań to ogólne koszty logistyczne, związane z funkcjonowaniem przedsiębiorstw transportowych w systemie miejskim (np. zewnętrzne koszty transportu, zużycie zasobów, itp.). Właściwa koordynacja i wykorzystanie posiadanej (lub potencjalnej) informacji, to główna cecha tej warstwy, która określa właściwe kierunki działań warstw niższych oraz prawidłowe funkcjonowanie systemu ILS.

Kolejna warstwa to adaptacja, której głównym celem funkcjonalnym jest dopasowywanie parametrów działania warstw niższych z głównymi celami warstwy zarządzania i koordynacji. Procesy występujące w logistyce miejskiej oraz główny komponent systemu transportowego miasta - ruch drogowy, są wysoce dynamiczne, losowe i często nieprzewidywalne. Dla przykładu, w odniesieniu do problematyki VRP, mogą to być sytuacje gdzie: nastąpiła nagle zmiana struktury i specyfiki zbioru klientów, zawiodły środki techniczne, wystąpiły nieprzewidywalne incydenty drogowe w sieci, czy też nastąpiła zmiana preferencji decydentów (planistów) firm transportowych. Jest dość oczywistym, że różnego rodzaju narzędzia do wspomaganiania decyzji, czy też metody optymalizacyjne są najbardziej efektywne w pewnych warunkach, dla specyficznej reprezentatywności struktury danych. Wiedzę tą można zapisać w formie bazy wiedzy. Badanie aktualnej sytuacji logistycznej¹⁸ i odnoszenie jej do bazy wiedzy o charakterystyce każdej z metod niższej warstwy, przy uwzględnieniu głównych celów logistycznych, to główna idea i zasada działania tej warstwy.

Warstwa optymalizacji to zbiór metod optymalizacyjnych procesów transportowych oraz logistycznych. Działanie ich jest ukierunkowane przez główne cele najwyższej warstwy na bazie danych otrzymanych z urządzeń pomiarowych, zaktualizowanych przez warstwę adaptacji baz wiedzy i reguł. Jest to miejsce styku przepływu informacji od urządzeń telematyki, głównie elementów systemów ILS i ITS. W odniesieniu do zagadnień VRP, warstwa ta może być biblioteką różnych odmian modeli matematycznych i problemów wyznaczania tras oraz zagadnień związanych z harmonogramowaniem pracy pojazdów i kierowców.

Każde wdrożone rozwiązanie podczas realizacji w rzeczywistym systemie wymaga monitoringu i nadzoru, który ma sprawdzać czy zmienne warunki otoczenia nie powodują, że bieżące, realizowane rozwiązanie jest nadal korzystne. Działanie monitoringu i nadzoru może być realizowane przez: proponowanie zmiany aktualnego rozwiązania na bardziej reprezentatywne przy zmienionych warunkach, wprowadzenia rekomendacji zmiany sterowania ruchem w mieście w celu minimalizacji ponoszonych strat przez dany typ uczestników ruchu przy jednoczesnym nie pogorszeniu parametrów poruszania pozostałych uczestników (wykorzystanie zbioru kompromisu w sensie Pareto) [2, 5].

Najniższa warstwa odpowiada za bezpośrednie sterowanie ruchem drogowym zgodnie z rekomendacjami warstw wyższych i aktualnych warunków ruchowych w mieście. Zadania te są realizowane m.in. przez urządzenia pomiarowe (np. wideo-detekcja), urządzenia pokładowe w pojazdach, znaki zmiennej treści, sterowniki skrzyżowań, czy też centra zarządzania ruchem. W przytaczanych koncepcjach proponowane są zaawansowane metody inteligentnego sterowania o nazwie PIACON¹⁹ oraz DISCON²⁰ [1, 2].

Zaprezentowana koncepcja w bardzo łatwy i prosty sposób może być zaimplementowana do procesu planowania tras pojazdów, w którym wykorzystuje się m.in. metody optymalizacji

¹⁸ Sytuacja logistyczna jest rozumiana jako ogół warunków, jakie mają wpływ na realizację zadań związanych z przepływami towarów w mieście, np. parametry ruchu drogowego, standardy obsługi klientów lub nagłe sytuacje losowe, wprowadzona doraźna, polityka zarządzania ruchem związana np. z przekroczeniem norm emisyjnych, itp.

¹⁹ PIACON (Polyoptimal Intelligent Adaptive CONtrol) - metoda sterowania ruchem drogowym wykorzystująca zaawansowane algorytmy optymalizacji wielokryterialnej.

²⁰ DISCON (DISpatching CONtrol) - zaawansowana metoda sterowania dyspozytorskiego.

odpornej na wahania parametrów modelu. Poszczególne zadania w obrębie każdej z warstw zaprezentowano w tabeli 2-5.

Tabela 2-5 Zadania warstw i narzędzia wspomagające w kontekście hierarchicznego systemu ILS dla problematyki wyznaczania tras pojazdów.

Warstwa ILS	Zadania etapu planowania transportu	Narzędzia ILS
Zarządzanie i koordynacja	<ul style="list-style-type: none"> ▪ Określenie celów strategicznych firmy transportowej ▪ Uwzględnienie ograniczenia dostępności transportowej miasta ▪ Uwzględnienie wytycznych polityki transportowej miasta ▪ Określenie posiadanych zasobów ▪ Uwzględnienie informacji o klientach i ich oczekiwaniach ▪ Uwzględnienie pozostałych informacji logistycznych 	<ul style="list-style-type: none"> ▪ Systemy ERP ▪ Systemy CRM ▪ Platformy internetowe dla klientów ▪ Narzędzia GIS ▪ Systemy WMS ▪ Metody wielokryterialnego wspomagania decyzji
Adaptacja	<ul style="list-style-type: none"> ▪ Aktualizacja bazy połączeń pomiędzy klientami ▪ Prognoza warunków ruchowych w oparciu a aktualne dane ruchowe ▪ Aktualizacja bieżącego zapotrzebowania klientów ▪ Pozyskanie informacji o aktualnej sytuacji ruchowej w sieci drogowej ▪ Określenie zbioru niepewności dla parametrów modelu VRP 	<ul style="list-style-type: none"> ▪ Moduły dla krótkookresowej prognozy parametrów ruchu ▪ Narzędzia wspomagania decyzji ▪ Baza wiedzy eksperckiej ▪ Narzędzia optymalizacji problemów SPP ▪ Usługi GPS, GSM
Optymalizacja	<ul style="list-style-type: none"> ▪ Rozpoznanie specyfikacji problemu VRP ▪ Wybór właściwego narzędzia ▪ Wyznaczenie tras pojazdów w sensie odpornym na zjawiska typowe i nietypowe w ruchu drogowym ▪ Harmonogramowanie kierowców i pojazdów 	<ul style="list-style-type: none"> ▪ Narzędzie wspomagania decyzji przy wyborze adekwatnego typu problemu VRP oraz metody optymalizacji ▪ Wielokryterialne metody optymalizacji tras pojazdów oparte o podejścia typu "robust" ▪ Narzędzia do optymalizacji przydziału zadań
Inteligentny nadzór	<ul style="list-style-type: none"> ▪ Bieżąca, inteligentna diagnoza sytuacji ruchowych ▪ Aktualizacja sytuacji ruchowej w sieci drogowej ▪ Wskazanie czy należy wykonać re-optymalizację bieżącego rozwiązania 	<ul style="list-style-type: none"> ▪ Komunikacja GPS, GSM ▪ Narzędzia teleinformatyczne
Sterowanie bezpośrednie	<ul style="list-style-type: none"> ▪ Kompromisowe uwzględnienie preferencji wszystkich uczestników ruchu ▪ Czy włączyć priorytet dla danej grupy użytkowników? ▪ Bieżące inteligentne dostosowywanie sterowania ruchem do aktualnych potrzeb 	<ul style="list-style-type: none"> ▪ Znaki zmiennej treści VMS ▪ Sterowniki sygnalizacji świetlnej ▪ Urządzenie pomiarowe ITS ▪ Urządzenie pokładowe pojazdów

Użyte skróty: ERP - system informatyczny do planowania zasobów przedsiębiorstwa; CRP - system informatyczny do zarządzania relacjami z klientami, WMS - system informatyczny do zarządzania magazynem; GIS - system informacji geograficznej; GPS - globalny system pozycjonowania; GSM - sieć telefonii komórkowej; SPP - problem najkrótszej ścieżki.

Źródło: opracowanie własne na podstawie [1, 3, 6, 7].

Większość zadań zdefiniowanych w tabeli powyżej są codziennymi elementami pracy ludzi pracujących w firmach transportowych i instytucjach zarządzających ruchem drogowym w miastach. Zatem zakres funkcjonalności występujący w koncepcji ILS jest reprezentatywnym opisem istniejącego stanu rzeczy, jednak istotna różnica to propozycja zintegrowanego podejścia systemowego bazującego na eksploracji technologii i nowoczesnych narzędzi sys-

temowych. Tylko spójna integracja procesów logistycznych może przynieść wymierne korzyści dla całego systemu miasta [5, 62, 97, 104].

Przedstawiona powyżej koncepcja ILS wraz z uwzględnieniem aspektów problematyki VRP może być bardzo dobrym przykładem kompleksowego opisu rozważanych zagadnień. Jak zaprezentowano to w dalszych częściach pracy, wyznaczanie tras pojazdów jest modelowane przy użyciu zbiorów niepewności (podrozdział 3.3). Do prawidłowego określenia tych zbiorów są konieczne historyczne i aktualne dane o parametrach ruchu. Stąd naturalnym się wydaje, że należy wykorzystać narzędzia np. prognostyczne, platformy z informacjami o aktualnym ruchu, które będą mogły wspomagać proces planowania. Drugim miejscem gdzie mogą być pomocne inteligentne narzędzia wspomagania decyzji, to etap wyboru parametru konserwatywności (podrozdział 3.3). Oczywiście może on być wybierany w oparciu o wiedzę dyspozytora, jednak jak pokazują aktualne kierunki badań na świecie, lepszą efektywnością charakteryzują się narzędzia sztucznej inteligencji, której działanie jest oparte na sformalizowanej wiedzy eksperta [3, 78, 79].

2.4 WNIOSKI Z ROZDZIAŁU NR 2

W rozdziale przedstawiono podstawowe pojęcia oraz charakterystykę dystrybucji towarów na obszarach miejskich oraz jej cech w ujęciu miasta, jako systemu logistycznego. Pomimo przeprowadzeniu szczegółowych analiz systemu logistycznego miasta przez naukowców z całego świata, propozycja zarządzania przepływami towarów nie oferuje jednoznacznie poprawnego panaceum na problemy towarzyszące realizacji procesów transportu. Poprzez występowanie skomplikowanych i złożonych relacji systemowych, większość obecnie występujących w rzeczywistości oraz rekomendowanych rozwiązań może generować pewne negatywne skutki w różnych obszarach. Dla przykładu wprowadzanie ograniczeń dostępności obszarów miasta poprzez wprowadzenie opłat za wjazd, będzie powodować złe nastroje wśród firm transportowych oraz będzie powodować dodatkowe koszty finansowe dla nich. Miejskie Centra Konsolidacji wzbudzają nieufność firm transportowych, w aspektach odpowiedzialności i jakości świadczonych usług przez MCK oraz są nieefektywne finansowo. "Rozwiązania ostatniego kilometra" często przenoszą koszty transportu na finalnych klientów (automatyczne skrytki pocztowe), itd.

Jednym z rekomendowanych rozwiązań przez odpowiednie jednostki UE, czy USA jest wprowadzanie do procesu planowania transportu przez podmioty realizujące transport w mieście, narzędzi zawierających metody optymalizujące trasy pojazdów. W kontekście tematyki pracy nasuwa się pytanie: Jakie efekty pozytywne i negatywne może przynieść wdrożenie metod optymalizacyjnych w planowaniu tras pojazdów? Do pozytywnych efektów można zaliczyć, lepsze wykorzystanie ładowności pojazdu, zmniejszenie kosztów operacyjnych, zmniejszenie czasu pracy pojazdu i kierowcy, zwiększenie poziomu świadczonych usług, zmniejszenie liczby użytych pojazdów, a co za tym idzie zmniejszenie emisji spalin oraz hałasu. Negatywne aspekty wdrożenia tego rozwiązania (występujące głównie po stronie firm transportowych) to: koszty zakupu odpowiedniego oprogramowania, koszty zatrudnienia specjalistów, możliwe do wystąpienia koszty wdrażania i dostosowywania metod optymalizacyjnych, koszty wyposażenie pojazdów w urządzenia lokalizacyjne oraz koszty pozyskania in-

formacji o aktualnym ruchu drogowym. Ostatnie dwa koszty na tą chwilę są znaczące dla firm, jednak jak pokazuje obecna tendencja, rozwój technologii ITS jest nieunikniony, wobec czego dostępność każdej wdrożonej technologii będzie łatwiejsza i tańsza. Fakt tendencji wprowadzania metod optymalizacji tras w swoje strategie można zauważyć wśród globalnych firm logistycznych i transportowych, które kładą nacisk na efektywność, ekonomiczność i ekologię [62].

Propozycja zastosowania optymalizacji tras pojazdom w logistyce miejskiej, może znaleźć swoje uzasadnienie we względnie niskich kosztach wdrożenia i implementacji oraz w znaczącej poprawie funkcjonowania i jakości transportu towarów w mieście. W przytaczanym raporcie Wydziału Mobilności i Transportu UE zestawiono kilkanaście rekomendacji i oceniono je pod względem wpływu ekonomicznego, środowiskowego, na zdrowie człowieka, określono stosunek jakości efektów rozwiązania do poniesionych nakładów wdrożenia oraz dla jakich wielkości miast dane rozwiązanie jest odpowiednie. Metody wyznaczania tras pojazdom zostały określone, jako rozwiązanie o niskim wpływie na koszty operacyjne dystrybucji transportu oraz na poziom zatłoczenia ulic. Rozwiązania tego typu mogą dać dobre efekty poprawy jakości powietrza, zmniejszenia emisji gazów cieplarnianych oraz zmniejszenia emisji hałasu. Możliwe jest uzyskanie bardzo dobrych efektów w kwestii oddziaływania dystrybucji towarów na zdrowie i bezpieczeństwo człowieka. Zaleca się aby planowanie transportu w oparciu o optymalizację marszrut pojazdów było stosowane w metropoliach europejskich (powyżej 3 mln mieszkańców) oraz w dużych miastach (pow. 0,5 mln mieszkańców). Dodatkowo stosunek jakości efektów rozwiązania do kosztów implementacji został określony jako dobry [97].

Przedstawione zalety stosowania tej klasy metod są dość oczywiste, czego egzemplifikacją jest duże zainteresowanie środowisk naukowych wyrażone poprzez stworzenie kilku tysięcy prac naukowych o tej tematyce. Jednakże jak wynika z wstępnej analizy literatury przedmiotu, w większości przeprowadzanych badań naukowych brakuje podstawowego założenia o opisywanym obiekcie, jakim jest miasto i ruch drogowy - występowanie nieokreśloności i niepewności zjawisk. Przyjęcie założenia, że system transportowy miasta jest przewidywalny w stu procentach oraz występujące w nim mechanizmy i zjawiska można określić (estymować) precyzyjnie przed ich rzeczywistą realizacją, nosi znamiona aberracji. System transportowy miasta oraz jego główny element jakim jest ruch drogowy charakteryzuje się dynamizmem, losowością, niepewnością, strukturalną niestabilnością oraz występują w nim skomplikowane interakcje wewnętrzne i zewnętrzne, których realizacja zależy od warunków zewnętrznych (np. atmosferycznych), zasobów technicznych oraz zachowań poszczególnych uczestników systemu [4].

Metodyka zawarta w pracy jest próbą uwzględnienia losowości i nieokreśloności ruchu drogowego w celu uzyskania poprawnego (bliższego) opisu rzeczywistości poprzez matematyczny model problematyki wyznaczania tras pojazdom. W dalszej części pracy przedstawiono charakterystykę ruchu miejskiego, przegląd dotychczasowych osiągnięć w literaturze przedmiotu oraz propozycję metodyki wyznaczania tras pojazdów uwzględniającą aspekty nieokreśloności parametrów ruchu drogowego i jego charakterystykę.

3 PROBLEM OPTYMALIZACJI TRAS POJAZDÓW W WARUNKACH NIEPEWNOŚCI NA OBSZARACH MIEJSKICH

3.1 ŹRÓDŁA NIEPEWNOŚCI DANYCH O PARAMETRACH MIEJSKIEGO RUCHU DROGOWEGO W MODELACH OPTYMALIZACYJNYCH

Implementacja matematycznych modeli w rzeczywistych procesach decyzyjnych musi być oparta na odpowiednich założeniach, które powinny być odzwierciedleniem realnych procesów. Podstawowym elementem modeli matematycznych, który jest takim założeniem, to rodzaj wykorzystywanych danych w modelu. Ze względu na łatwość implementacji, najbardziej popularny typ danych to dane deterministyczne. Przyjęcie danych deterministycznych w modelu matematycznym tworzy model deterministyczny. Oznacza to, że posiadane informacje o parametrach danego procesu są dokładnie znane z góry, przed realizacją procesu decyzyjnego. W odniesieniu do charakterystyki procesu transportowego występującego w warunkach miejskich oraz do jego otoczenia, założenie to jest niezbyt realistyczne.

W problematyce wyznaczania tras jednym z podstawowych danych są informacje o czasach przejazdu na poszczególnych odcinkach sieci drogowej, które są w bardzo wysokim stopniu wrażliwe na zmiany swoich wartości. Podatność tych danych na zmianę wartości wynika z podstawowych cech i własności systemu transportowego miasta, które przedstawiono w tabeli 3-1.

Tabela 3-1 Cechy charakterystyczne systemu transportowego miasta.

CECHA	CHARAKTERYSTYKA
Niejednorodność	Składa się z elementów naturalnych, sztucznych oraz socjotechnicznych
Złożone zjawiska ruchowe	Występuje losowość i nieokreśloność zjawisk; istnieje wiele klas użytkowników oddziaływujących wzajemnie na siebie; struktura systemu transportowego miasta jest niestabilna
Szerokie spektrum procesów decyzyjnych	Możliwość zarządzania, sterowania, harmonogramowania, pełnienia nadzoru; Wielokryterialność decyzji; występowanie behawioralnych sprzężeń zwrotnych
Hierarchia	Każdy z podsystemów jest powiązany hierarchicznie z pozostałymi podsystemami
Nierównomierność	Infrastruktury drogowej; przestrzenna; obszarowa skutkująca występowaniem na przykład zatłoczenia
Adaptacyjność	Możliwość do samoorganizacji oraz uczenia się
Celowość	Każdy proces jest ukierunkowany na wypełnienie określonych zadań
Dynamiczność	System jest podatny na interakcje zewnętrzne (np. warunki pogodowe) i wewnętrzne (np. zachowanie użytkowników)

Źródło: opracowanie własne na podstawie [4, 149].

W celu właściwego planowania tras pojazdów, które wykonują obsługę towarową danego obszaru miasta, konieczne jest uwzględnienie wspomnianych własności w tymże procesie optymalizacyjnym. Przytoczone powyżej czynniki mogą wpływać m.in. na zmianę parametrów ruchu drogowego, co w konsekwencji tworzy niepewność wartości posiadanych danych. *Niepewność danych wynika z natury oraz charakterystyki opisywanego zjawiska i oznacza niemożliwość ustalenia dokładnych, przyszłych wartości danych w trakcie realizacji procesu decyzyjnego* [80].

Źródłami niepewności danych o parametrach ruchu drogowego w mieście mogą być:

1. Błędy prognozy parametrów ruchu drogowego,
2. Błędy pomiaru parametrów ruchu drogowego,
3. Nieokreśloność (brak) pomiaru parametrów ruchu drogowego,
4. Implementacja uzyskanego rozwiązania w rzeczywistym systemie transportowym,
5. Występowanie zjawisk rekurencyjnych,
6. Występowanie nietypowych zjawisk drogowych.

W systemie transportowym miasta dokładne rzeczywiste wartości danych o tym systemie zawsze są uzyskiwane po fakcie (automatycznie stają się historycznymi danymi). Stosowanie danych historycznych do planowania przyszłych procesów rzeczywistych zawsze będzie obarczone pewnym stopniem niepewności lub nieokreśloności. Jest to związane m.in. z błędem prognozy jak również charakterem losowości opisywanego procesu [81]. Mając na uwadze osobliwość ruchu drogowego, jaka została przedstawiona w tabeli 3-1, wartości prognozy mogą być obarczone dużymi błędami estymacji.

Przy obecnym postępie technologicznym rozwoju urządzeń pomiarowych, pozyskanie informacji o parametrach ruchu drogowego nie stanowi większego problemu. Jednakże, niezależnie od sposobu wykonania pomiaru oraz zastosowanej technologii, każdy pozyskany zbiór danych o ruchu drogowym będzie obarczony błędem pomiaru. Błąd ten jest źródłem niepewności posiadanych danych, ponieważ nie można określić ze stu procentową dokładnością rzeczywistych przyszłych wartości.

Dodatkowo, w rzeczywistym systemie transportowym wyposażenie w infrastrukturę pomiarową wszystkich odcinków sieci, wszystkich pasów ruchu oraz wszystkich skrzyżowań jest dość problematyczne i kosztowne. Z tego powodu część informacji o odcinkach, gdzie nie wykonuje się pomiaru ruchu, będzie estymowana na bazie wartości z przyległych pomiarów, co generuje nieokreśloność danych. Dane te, tak jak dane prognozowane są obarczone błędem predykcji.

Kolejnym źródłem niepewności podczas planowania tras przejazdu jest sama implementacja uzyskanego rozwiązania [22]. 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 niepewność poprawnej implementacji tego rozwiązania.

Przy dobrze rozwiniętej infrastrukturze pomiarowej możliwe jest definiowanie, badanie oraz przewidywanie typowych zjawisk drogowych. Przykładem zjawiska rekurencyjnego (typowego) mogą być szczyty komunikacyjne poranne i popołudniowe, które wykazują po-

wtarzalność dla roboczych dni tygodnia w podobnych godzinach. Na podstawie zjawisk rekurencyjnych można tworzyć tzw. wzorce ruchowe (ang. traffic patterns), które umożliwiają uwzględnienie w modelowaniu matematycznym powtarzalnych zmian w ruchu drogowym. Jednakże próba opisywania tych zjawisk sprowadza się do korzystania z metod prognostycznych, które cechują się, jak to wspomniano, błędem predykcji.

Ostatnie źródło niepewności, to zjawiska nietypowe lub nie rekurencyjne. Zjawisko nie rekurencyjne, to losowe zdarzenie w sieci drogowej powodujące nietypową (nieprzewidywalną) zmianę parametrów ruchu [13]. Można do nich zaliczyć: incydenty drogowe, nagła zmiana warunków pogodowych, niedostosowywanie się użytkowników do obowiązującego prawa drogowego (np. nieuprawniony wjazd na obszar skrzyżowania), roboty drogowe, awarie elementów infrastruktury drogowej oraz zdarzenia o charakterze społecznym (np. marsze, manifestacje, itp.). Wszystkie te nietypowe incydenty są trudne lub wręcz niemożliwe do przewidzenia.

Przedstawiona powyżej charakterystyka prowadzi do wniosku, że stosowanie metod modelowania matematycznego bez uwzględnienia niepewności wartości danych w problemach rzeczywistych nie ma większego uzasadnienia. Niestety, w literaturze przedmiotu najpopularniejszym podejściem opisywania niepewności jest teoria programowania stochastycznego [146]. O ile do opisu powtarzalnych zjawisk, tj. szczyt komunikacyjny, stosowanie ich może być właściwym podejściem, to przy zjawiskach nietypowych używanie modeli stochastycznych może być nieodpowiednie. Charakterystykę obu podejść, wad oraz zalet przedstawia kolejny podrozdział.

3.2 CHARAKTERYSTYKA TEORII OPTYMALIZACJI ODPORNEJ NA WAHANIA PARAMETRÓW MODELU MATEMATYCZNEGO

Optymalizacja odporna na wahania parametrów modelu²¹ (ang. Robust Optimization) jest dziedziną z zakresu teorii optymalizacji, w której parametry modelu są losowe lub nie są dokładnie, z góry znane (tzw. dane niepewne lub dane nieokreślone). Model matematyczny, w którym występują wartości parametrów niepewnych będzie się nazywać niepewnym modelem matematycznym (ang. uncertain model/formulation). Rozwiązanie niepewnego modelu można uzyskać m.in. przy pomocy: optymalizacji stochastycznej lub optymalizacji odpornej na wahania parametrów modelu. Rozwiązaniem modelu niepewnego jest tzw. rozwiązanie optymalne w sensie 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 rozwiązanie takiego problemu będzie odporne na zmiany wahań tego parametru w zakresie, jaki został założony w modelu, czyli [100%, 150%]. W przypadku problematyki VRP, rozwiązanie odporne może dawać informacje, kiedy powinno się uruchomić procedurę ponownego przeliczenia trasy lub re-marszrutyzacji (ang. rerouting vehicle problem), w celu ustalenia nowej,

²¹ Inne sformułowanie funkcjonujące w literaturze polskiej to optymalizacja odpornościowa, optymalizacja odporna lub optymalizacja typu "robust".

aktualnej kolejności odwiedzania klientów lub ustalenia nowego przebiegu trasy. Jednak jak pokazują dalsze rozważania, optymalizacja typu "robust" posiada cechy stabilności rozwiązania nawet po przekroczeniu założonych wartości (szczegóły w rozdziale 6).

Nieuwzględniona niepewność danych na etapie planowania może skutkować wygenerowaniem rozwiązania, które przy rzeczywistej realizacji będzie przynosić zbędne koszty. W pracy [23] przedstawiono analizę problemów programowania liniowego z bazy danych NETLIB²², z której wynika, że nawet niewielka zmiana wartości danych wejściowych - 0,01%, powodowała niezachowanie ograniczeń problemu nawet o 210%. Ograniczeniem dla problematyki marszrutyzacji może być na przykład przyjazd pojazdu do klienta w odpowiednim oknie czasowym. Innym przykładem wpływu wahań parametrów modelu przedstawia praca [6], gdzie analizowano zagadnienie wyznaczania tras pojazdom z oknami czasowymi (VRP-TW). 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 klientów.

Jak to wspomniano wcześniej, opisywanie niepewnych modeli matematycznych może być uzyskane poprzez dwa podejścia²³:

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

W metodyce stochastycznej zakłada się, że parametry modelu mogą być losowe. Celem podejścia stochastycznego jest odnalezienie takiego rozwiązania, które jest dopuszczalne dla wszystkich lub prawie wszystkich możliwych scenariuszy. Poprzez dopuszczalny scenariusz rozumiany jest przypadek, który mieści się w zakresie zmienności parametrów modelu. Zazwyczaj poszukiwanie rozwiązania jest oparte o maksymalizację wartości oczekiwanej zmiennych losowych. Zastosowanie podejścia stochastycznego przy modelowaniu rzeczywistych obiektów jest właściwe, jeśli spełnione są cztery warunki [22]:

1. Jeżeli parametry niepewne modelu wykazują naturę stochastyczną,
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 obliczeniową (algorytmiczną)²⁴ (ang. computationally trackable) [26].

²² Biblioteka numeryczna NETLIB [103] jest ogólnie dostępną bazą danych, gdzie zawarte są zbiory danych problemów numerycznych i optymalizacyjnych oraz zestawy narzędzi do wykonywania optymalizacji. Jest ona prowadzona i zarządzana przez laboratorium AT&T Bell, Uniwersytet w Tennessee oraz laboratorium Oak Ridge National Laboratory.

²³ W literaturze przedmiotu można również odnaleźć podejście oparte na zbiorach rozmytych wykorzystujące logikę rozmytą. Jednakże, głównym założeniem logiki rozmytej jest rozszerzenie rozumowania boolowskiego, w celu opisywania zjawisk poprzez zmienne lingwistyczne [158]. W rozważanych problemach nie występują elementy, które byłyby opisywane takimi zmiennymi, dlatego podejście to zostało pominięte.

Często przedstawione warunki są zbyt restrykcyjne dla rzeczywistych procesów, szczególnie transportowych. Po pierwsze, w celu opisanego dowolnego losowego zjawiska rzeczywistego poprzez odpowiedni wielowymiarowy rozkład prawdopodobieństwa jest potrzebna bardzo duża (często nierzeczywista) liczba obserwacji obiektu [65]. 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 niełatwa [22].

Trzecie założenie podejścia stochastycznego w zastosowaniu do rzeczywistych realizacji dystrybucji towarów jest dość kontrowersyjne. Zgodnie z jego założeniem decydenci procesu decyzyjnego akceptują z pewnym poziomem prawdopodobieństwa, że ograniczenia modelu matematycznego danego zjawiska zostaną zachowane. Nawiązując do zagadnienia marszrutyzacji, planista transportu przy tworzeniu harmonogramu rozwożenia towarów, musiałby np. akceptować z 95% prawdopodobieństwem, że dany towar zostanie dostarczony we właściwych ramach czasowych. Z punktu widzenia firmy transportowej, w najgorszym przypadku mogłoby to oznaczać 95% jakość obsługi²⁵. Zgodnie z teorią programowania z zadanymi prawdopodobieństwami realizacji ograniczeń, zwiększenie poziomu prawdopodobieństwa prowadzi do uzyskania rozwiązania wysoce pesymistycznego. Jest to spowodowane podstawową cechą tego typu programowania - większe przyjęte prawdopodobieństwo zwiększa zakres zmienności zmiennej losowej.

W celu rozwiązania modelu stochastycznego, konieczne jest sformułowanie ekwiwalentnego odpowiednika oryginalnego problemu, często poprzez jego aproksymację [122]. Podejście to niejednokrotnie implikuje trudności przy rozwiązywaniu aproksymacji modelu, a dokładnie może nie istnieć algorytm lub metoda, która rozwiązałaby ten problem w rozsądnym i akceptowalnym czasie. Takie sformułowanie problemu posiada cechę "niedostępności obliczeniowej" [28, 65], czyli uzyskanie rozwiązania może być w ogóle niemożliwe lub zajęłoby to bardzo dużo czasu obliczeniowego.

Drugim typem podejścia uwzględniającej niepewność danych modelu jest podejście odporne na wahania. Wywodzi się ona z automatyki, a dokładnie z teorii sterowania odpornego na wahania parametrów (ang. Robust Control). W optymalizacji odpornościowej nie zakłada się znajomości rozkładu prawdopodobieństwa losowej zmienności parametrów; przyjmuje się, 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 parametrów o wartościach niepewnych, lub w zaawansowanych formach poprzez wartość oczekiwaną, odchylenie standardowe, czy też kowariancję parametrów modelu [27, 65, 66].

Założenia obu typów optymalizacji posiadają swoje wady i zalety. Jeśli jest znany dokładny rozkład prawdopodobieństwa danych modelu, to rozwiązanie uzyskane z optymaliza-

²⁴ 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 "niedostępny obliczeniowo", jeżeli czas uzyskania rozwiązania nie zostanie uzyskany w czasie wielomianowym - problem NP.

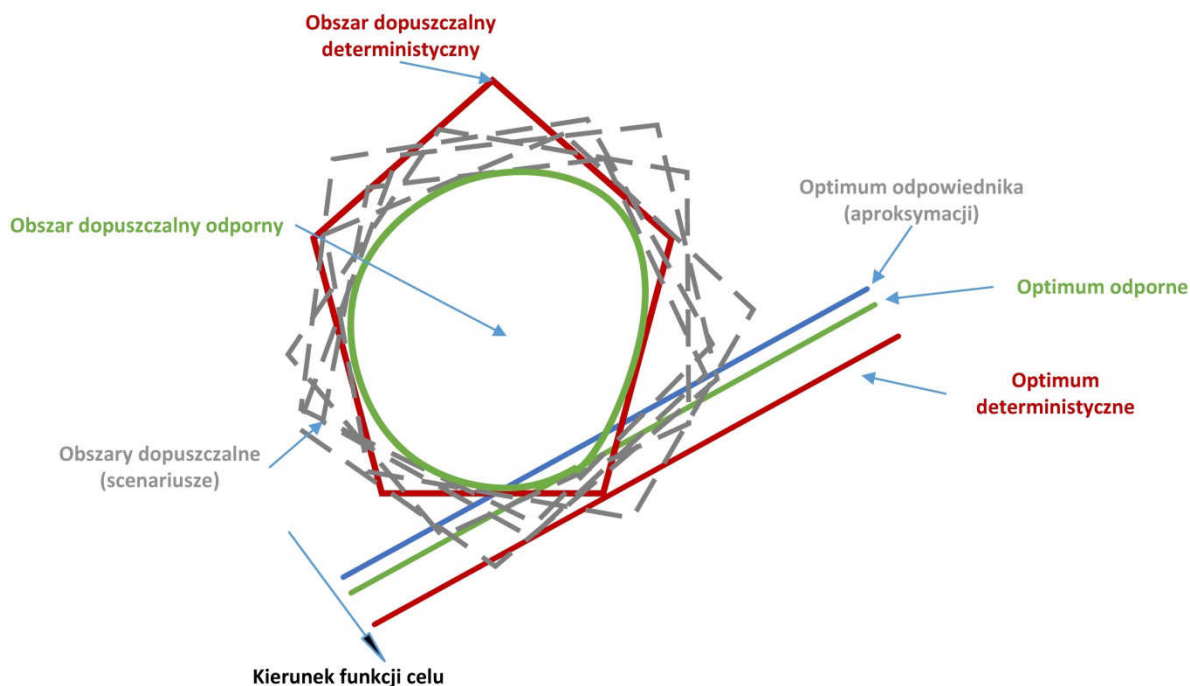
²⁵ Jakość obsługi jest rozumiana jako skuteczność trafiania przez kierowcę w okno czasowe u klienta.

cji odpornościowej może być bardziej i niepotrzebnie konserwatywne. Jeśli z kolei rzeczywisty rozkład prawdopodobieństwa danych będzie inny od założonego, rozwiązanie stochastyczne może być dać rezultat niesatysfakcjonujący - zrealizowana niepewność może okazać się większa niż wynikało to z rozkładu, przez co zrealizowane rozwiązanie może wygenerować dodatkowe koszty. Takie rozwiązanie może być nieodpowiednio uodpornione na wahania w wartościach parametrów, co będzie nieoptymalne.

Głównym założeniem podejścia odpornościowego przeciwie, niż w optymalizacji stochastycznej, jest zachowanie wszystkich ograniczeń modelu w stu procentach lub z bardzo wysokim prawdopodobieństwem. Oznacza to, że uzyskane odporne rozwiązanie będzie dopuszczalne dla wszystkich możliwych scenariuszy określonych zbiorem niepewności. W przypadku minimalizacji, celem jest wybór scenariusza o najmniejszym koszcie zdefiniowanym funkcją kryterialną. W klasycznym podejściu, założenie to prowadzi do poszukiwania rozwiązania najlepszego z najgorszych (ang. worst-case-oriented), co jest często wskazywane w literaturze, jako wada tego podejścia [36, 65, 144]. Optymalizacja zorientowana na wybór najlepszego z najgorszych, tzw. min-max, może prowadzić do ponad konserwatywnego rozwiązania. Rozwiązanie cechujące się ponad konserwatywnością, to rozwiązanie które zostało uzyskane przez przyjęcie pesymistycznych, zbyt dużych wartości parametrów modelu, co skutkuje ponoszeniem zbędnych kosztów podczas implementacji takiego rozwiązania. Jednakże niedogodność ta może być rozwiązywana poprzez zastosowanie parametrów kontrolujących poziom konserwatywności rozwiązania [27, 28, 65, 66]. Jedną z takich metod jest przyjęcie, że zmienne decyzyjne są afinicznie zależne od zmiennych nieokreślonych²⁶.

W celu łatwiejszego wyobrażenia powyższych rozważań, na rysunku 3.1, przedstawiono poglądową charakterystykę modeli zawierających niepewne parametry oraz ich realizację przy pomocy optymalizacji odpornościowej.

²⁶ W modelach uwzględniających niepewność danych wprowadza się dodatkową zmienną tzw. zmienną nieokreśloną (ang. uncertain variable), która jest dodawana w celu uproszczenia modelowania matematycznego.



Rysunek 3.1 Poglądowy schemat idei poszukiwania rozwiązania w optymalizacji odpornościowej

Źródło: opracowanie własne na podstawie [52]

Obszar dopuszczalny problemu nominalnego (deterministycznego) jest większy niż obszar dopuszczalny problemu uwzględniającego niepewność wartości danych (obszar dopuszczalny odporny). Wynika to z paradygmatów optymalizacji odpornościowej, które zakładają, że optymalne rozwiązanie w sensie odpornym musi być dopuszczalne dla wszystkich scenariuszy zbioru niepewności. Konsekwencją takiego założenia jest ponoszenie dodatkowych kosztów związanych z uodpornieniem rozwiązania na zmienność parametrów. Koszt ten w literaturze przedmiotu został zdefiniowany, jako "cena uodpornienia" (ang. Price of Robustness) [27]. W przypadku minimalizacji problemu wartość funkcji celu dla nominalnego problemu będzie mniejsza niż wartość funkcji celu problemu odpornego (rysunek 3.1).

Model matematyczny odporny na wahania parametrów modelu rzeczywistych problemów, często może być formalnie sformułowany w sposób nieefektywny lub wręcz niemożliwy do rozwiązania. W celu uniknięcia takiej sytuacji metodyka optymalizacji odpornej zakłada tworzenie odpornościowych odpowiedników modelu²⁷ lub (i dodatkowo) zastosowanie aproksymacji odpornościowego odpowiednika. W związku z tym, że finalny model problemu jest poddany takim procesom, optymalne rozwiązanie tak sformułowanego modelu może być obciążone większą ceną uodpornienia.

Przedstawiona krótka charakterystyka dwóch metod radzenia sobie z danymi niepewnymi w modelowaniu matematycznym wskazuje na wady i zalety obu. Wybór odpowiedniej meto-

²⁷ Odpornościowy odpowiednik modelu (ang. robust counterpart of model) lub odporny odpowiednik modelu jest to matematyczne przeformułowanie niepewnego problemu, którego proces rozwiązywania (optymalizacji) posiada cechę dostępności obliczeniowej. Oryginalne niepewne modele matematyczne często są sformułowane w postaci, która prowadzi do niedostępności obliczeniowej, co skutkuje niemożliwością uzyskania rozwiązania takiej postaci. Pierwotna postać modelu, w którym występuje niepewność danych jest formułowana tylko w celu logicznego i formalnego opisu obiektu rzeczywistego.

dy powinien uwzględniać charakterystykę opisywanego obiektu, bądź systemu. W pracy obiektem badań jest problem rozwożenia towarów do klientów funkcjonujący w systemie transportowym miasta. Niepewność parametrów tego obiektu jest trudna do zbadania i opisanie przy pomocy konkretnego wzoru matematycznego. Pożądanym jest, aby zdefiniowane założenia modelu matematycznego były spełnione z dużym prawdopodobieństwem, a nie z pewną dozą prawdopodobieństwa. Wobec czego według autora wydaje się być zasadnym stosowanie metodyki optymalizacji typu "robust" odpornej na wahania parametrów w odniesieniu do problematyki wyznaczania tras pojazdów w warunkach miejskich.

3.3 MODEL NIEPEWNOŚCI DANYCH W PROGRAMOWANIU LINIOWYM

Problematyka wyznaczania tras pojazdów została sformułowana w postaci programowania liniowego całkowitoliczbowego, stąd dalsza część tego podrozdziału będzie się ograniczać do przedstawienia metodyki modelowania niepewności wartości parametrów w optymalizacji liniowej. Celem podrozdziału jest przedstawienie ogólnych założeń odpornej optymalizacji liniowej, wprowadzenia podstawowych pojęć oraz metodyki rozwiązywania modeli matematycznych gdzie parametry są opisane w formie przedziałowej oraz w których zmienne mogą przyjmować wartości całkowite. Przedstawiona poniżej teoria, definicje oraz metodyka jest oparta o prace [22, 27, 28].

3.3.1 PROGRAMOWANIE LINIOWE TYPU ROBUST - CHARAKTERYSTYKA OGÓLNA

Problem programowania liniowego (*PL*) można przedstawić następująco (zapis deterministyczny):

$$(PL): \min_x \{ \mathbf{c}^T \mathbf{x} + g : \mathbf{A} \mathbf{x} \leq \mathbf{b} \} \quad (3.1)$$

gdzie:

$\mathbf{x} \in \mathbb{R}^n$ - wektor zmiennych decyzyjnych problemu,

$\mathbf{c} \in \mathbb{R}^n$ - wektor współczynników funkcji kryterialnej,

g - stała funkcji kryterialnej,

$\mathbf{A} \in \mathbb{R}^{m \times n}$ - macierz współczynników ograniczeń,

$\mathbf{b} \in \mathbb{R}^m$ - wektor prawej strony ograniczeń,

W problemie występuje zbiór $\mathbf{N} = \{1, 2, \dots, n\}$, gdzie n to liczba zmiennych decyzyjnych oraz zbiór $\mathbf{M} = \{1, 2, \dots, m\}$, gdzie m to liczba ograniczeń. Struktura problemu (*PL*) może być przedstawiona w postaci macierzy danych \mathbf{D} o wymiarach $(m+1)$ na $(n+1)$:

$$\mathbf{D} = \begin{bmatrix} \mathbf{c}^T & g \\ \mathbf{A} & \mathbf{b} \end{bmatrix} \quad (3.2)$$

Definicja 1. *Problem programowania liniowego (PL) uwzględniający niepewność wartości danych nazywa się niepewnym modelem programowania liniowego i formalnie można go przedstawić następująco:*

$$(PL_{\mathcal{U}}): \{\min_x \{\tilde{\mathbf{c}}^T \mathbf{x} + \tilde{g}: \tilde{\mathbf{A}} \mathbf{x} \leq \tilde{\mathbf{b}}\}\}_{(\tilde{\mathbf{c}}, \tilde{g}, \tilde{\mathbf{A}}, \tilde{\mathbf{b}}) \in \mathcal{U}} \quad (3.3)$$

gdzie:

$\tilde{\mathbf{c}} \in \mathbb{R}^n$ - wektor współczynników funkcji kryterialnej poddanych zaburzeniom wartości,

\tilde{g} - stała funkcji kryterialnej poddana zaburzeniom wartości,

$\tilde{\mathbf{A}} \in \mathbb{R}^{m \times n}$ - macierz współczynników ograniczeń poddanych zaburzeniom wartości,

$\tilde{\mathbf{b}} \in \mathbb{R}^m$ - wektor prawej strony ograniczeń poddany zaburzeniom wartości,

$\mathcal{U} \in \mathbb{R}^{(m+1) \times (n+1)}$ - zbiór niepewności danych $\tilde{\mathbf{D}}$ modelu $(PL_{\mathcal{U}})$,

$\tilde{\mathbf{D}} \in \mathbb{R}^{(m+1) \times (n+1)}$ - dane modelu $(PL_{\mathcal{U}})$ poddane perturbacjom.

Uwaga 1. Zakłada się, że zbiór niepewności \mathcal{U} , w którym dane $\tilde{\mathbf{D}}$ mogą przyjmować swoje losowe wartości, jest sparametryzowany w postaci afinicznej:

$$\mathcal{U} = \left\{ \begin{bmatrix} \tilde{\mathbf{c}}^T & \tilde{g} \\ \tilde{\mathbf{A}} & \tilde{\mathbf{b}} \end{bmatrix} = \begin{bmatrix} \bar{\mathbf{c}}^T & \bar{g} \\ \bar{\mathbf{A}} & \bar{\mathbf{b}} \end{bmatrix} + \sum_{\ell=1}^{\mathcal{L}} \xi_{\ell} \begin{bmatrix} \hat{\mathbf{c}}^T & \hat{g} \\ \hat{\mathbf{A}} & \hat{\mathbf{b}} \end{bmatrix} : \xi \in \mathcal{Z} \subset \mathbb{R}^{\mathcal{L}} \right\} \quad (3.4)$$

gdzie:

$\begin{bmatrix} \bar{\mathbf{c}}^T & \bar{g} \\ \bar{\mathbf{A}} & \bar{\mathbf{b}} \end{bmatrix} = \bar{\mathbf{D}}$ - macierz, która reprezentuje nominalne wartości danych problemu $(PL_{\mathcal{U}})$,

$\begin{bmatrix} \hat{\mathbf{c}}^T & \hat{g} \\ \hat{\mathbf{A}} & \hat{\mathbf{b}} \end{bmatrix} = \hat{\mathbf{D}}$ - macierz, która reprezentuje zakres potencjalnych zmian danych modelu $(PL_{\mathcal{U}})$ od wartości nominalnych $\bar{\mathbf{D}}$,

ξ_{ℓ} : $\xi \in \mathcal{Z}$ - wektor losowej perturbacji przyjmujący swoje wartości w zbiorze perturbacji \mathcal{Z} ,

$\mathcal{Z} \subset \mathbb{R}^{|\mathcal{L}|}$ - zbiór losowych perturbacji modelu niepewnego $(PL_{\mathcal{U}})$, gdzie $\mathcal{L} = \{1, \dots, \ell, \dots, |\mathcal{L}|\}$ reprezentuje zbiór indeksów potencjalnych scenariuszy zaburzeń.

Sformułowanie niepewnego modelu liniowego $(PL_{\mathcal{U}})$ przy założeniach afiniczności zbioru niepewności (3.4) powoduje, że terminy tj. "rozwiązanie optymalne/dopuszczalne" oraz "wartość optymalna", nie są już rozumiane w taki sam sposób jak w optymalizacji typu (PL) . Rozumienie tych pojęć jest ściśle związane z warunkami procesu decyzyjnego. Klasyczna teoria optymalizacji odpornej przyjmuje trzy założenia:

1. Wszystkie zmienne niepewnego modelu $(PL_{\mathcal{U}})$ reprezentują decyzje "tu i teraz" (ang. here and now decisions); ich wartość powinna być ustalona po i na podstawie wyniku optymalizacji oraz przed aktualizacją rzeczywistych wartości danych \mathbf{D} ,
2. Decydent jest w pełni odpowiedzialny za potencjalne konsekwencje podjętych decyzji wtedy i tylko wtedy, gdy rzeczywiste wartości zawierają się w zakresie wyznaczonym przez zbiór \mathcal{U} zdefiniowany w (3.4),
3. Wszystkie ograniczenia w modelu $(PL_{\mathcal{U}})$ w ramach zmienności danych wyznaczonych przez zbiór \mathcal{U} , są ograniczeniami "twardymi", tzn. prawdopodobieństwo nie zachowania ograniczenia jest równe zero.

Przedstawione powyżej założenia określają sposób rozumienia dopuszczalności rozwiązania niepewnego modelu ($PL_{\mathcal{U}}$), czyli dane rozwiązanie o stałych wartościach jest dopuszczalne w sensie odpornym (ang. Robust feasible), gdy dla wszystkich realizacji scenariuszy ze zbioru niepewności wartości danych zostaną zachowane wszystkie ograniczenia modelu. Na podstawie przytoczonych założeń można zdefiniować pojęcie dopuszczalności rozwiązania w sensie odpornym:

Definicja 3. Dla niepewnego modelu ($PL_{\mathcal{U}}$) wektor $\mathbf{x} \in \mathbb{R}^n$ jest rozwiązaniem dopuszczalnym w sensie odpornym, jeśli dla wszystkich realizacji scenariuszy zbioru niepewności \mathcal{U} spełnia on wszystkie ograniczenia:

$$\tilde{\mathbf{A}}\mathbf{x} \leq \tilde{\mathbf{b}}, \forall (\tilde{\mathbf{c}}, \tilde{g}, \tilde{\mathbf{A}}, \tilde{\mathbf{b}}) \in \mathcal{U}$$

Definicja 4. Dla potencjalnego rozwiązania \mathbf{x} , wartość odporna: $\mathbf{f}^*(\mathbf{x})$ dla wszystkich realizacji scenariuszy zbioru niepewności danych modelu ($PL_{\mathcal{U}}$) jest określona przez największą możliwą wartość rzeczywistej funkcji kryterialnej $\mathbf{c}^T \mathbf{x} + g$, taką, że:

$$\mathbf{f}^*(\mathbf{x}) = \sup_{(\tilde{\mathbf{c}}, \tilde{g}, \tilde{\mathbf{A}}, \tilde{\mathbf{b}}) \in \mathcal{U}} [\tilde{\mathbf{c}}^T \mathbf{x} + \tilde{g}] \quad (3.5)$$

Definicja 4 przedstawia sposób oceniania potencjalnego rozwiązania, co w konsekwencji prowadzi do możliwości określenia najlepszej wartości odpornej spośród zbioru wartości odpornych. Takie założenia prowadzą do głównej koncepcji optymalizacji odpornej - odpornych odpowiedników modeli niepewnych, które można zdefiniować następująco:

Definicja 5. Model odpornego odpowiednika niepewnego modelu programowania liniowego ($PL_{\mathcal{U}}$) można sformułować następująco:

$$(RC): \min_{\mathbf{x}} \left\{ \mathbf{f}^*(\mathbf{x}) = \sup_{(\tilde{\mathbf{c}}, \tilde{g}, \tilde{\mathbf{A}}, \tilde{\mathbf{b}}) \in \mathcal{U}} [\tilde{\mathbf{c}}^T \mathbf{x} + \tilde{g}] : \tilde{\mathbf{A}}\mathbf{x} \leq \tilde{\mathbf{b}}, \forall (\tilde{\mathbf{c}}, \tilde{g}, \tilde{\mathbf{A}}, \tilde{\mathbf{b}}) \in \mathcal{U} \right\} \quad (3.6)$$

Stąd wniosek, że optymalne rozwiązanie modelu (RC) jest optymalnym rozwiązaniem odpornym modelu niepewnego ($PL_{\mathcal{U}}$) (ang. robust optimal solution). Analogicznie, optymalna wartość modelu odpornego odpowiednia (RC) jest optymalną wartością odporną modelu niepewnego ($PL_{\mathcal{U}}$) (ang. robust optimal value). Odporność rozwiązania niepewnego modelu jest również definiowana, jako pojęcie poziomu konserwatyizmu rozwiązania.

Jednym z celów pracy jest wprowadzenie niepewności wartości danych odnoszących się do czasu przejazdu przez odcinki drogowe sieci oraz do czasu obsługi klienta. W zaproponowanych modelach wyznaczania tras pojazdów ($nVRP1^T$) oraz ($nVRP2^T$)²⁸ dane te są uwzględnione w ograniczeniach, czyli przenosząc to na ogólny zapis problemów liniowych, dotyczy to tylko macierzy współczynników ograniczeń \mathbf{A} oraz prawej strony ograniczeń \mathbf{b} . Oznacza to, że funkcja kryterialna niepewnego problemu ($PL_{\mathcal{U}}$) jest pewna, tzn. nie występują w niej parametry o wartościach nieokreślonych. W zapisie ogólnym problem ten można zapisać następująco (na tą chwilę pomijane są założenia o binarności zmiennych):

²⁸ Zob. podrozdział 4.1

$$(PL1_U): \left\{ \min_{\mathbf{x}} \{ \mathbf{c}^T \mathbf{x} : \tilde{\mathbf{A}} \mathbf{x} \leq \tilde{\mathbf{b}} \} \right\}_{(\tilde{\mathbf{A}}, \tilde{\mathbf{b}}) \in \mathbf{U}} \quad (3.7)$$

Analizując tylko i wyłącznie zapis ograniczeń modelu $(PL1_U)$, ograniczenia te można przeformułować do postaci wierszowej tzn.: $(\tilde{\mathbf{A}}\mathbf{x})_i \leq \tilde{b}_i \Leftrightarrow \tilde{a}_i^T \mathbf{x} \leq \tilde{b}_i$, czyli \tilde{a}_i^T jest i-tym ograniczeniem modelu. Przenosząc tę analogię na model (RC) , postać ograniczeń można zapisać jako: $\tilde{a}_i^T \mathbf{x} \leq \tilde{b}_i, \forall [\tilde{a}_i, \tilde{b}_i] \in \mathbf{U}_i$, gdzie \mathbf{U}_i - jest projekcją i-tego ograniczenia w zbiorze \mathbf{U} , taką, że: $\mathbf{U}_i = \{[\tilde{a}_i, \tilde{b}_i] : [\tilde{\mathbf{A}}, \tilde{\mathbf{b}}] \in \mathbf{U}\}$. Zakłada się, że zbiory niepewności poszczególnych ograniczeń \mathbf{U}_i są domknięte oraz wypukłe. Oznacza to, że odporny odpowiednik (RC) z funkcją kryterialną niepoddaną niepewności pozostaje niezmienny, wtedy, gdy oryginalny zbiór niepewności \mathbf{U} jest uogólnionym iloczynem kartezjańskim projekcji zbiorów niepewności poszczególnych ograniczeń w przestrzeni, które można wyrazić:

$\hat{\mathbf{U}} = \mathbf{U}_1 \times \dots \times \mathbf{U}_i \dots \times \mathbf{U}_m$. Przyjmując założenie o afiniczności danych niepewnych, zbiór niepewności i-tego ograniczenia można zapisać:

$$\mathbf{U}_i = \{[\tilde{a}_i, \tilde{b}_i] = [\bar{a}_i, \bar{b}_i] + \sum_{\ell}^{\mathcal{L}_i} \xi_{\ell} [a_i^{\ell}; b_i^{\ell}] : \xi \in \mathcal{Z}_i\} \quad (3.8)$$

Reasumując, biorąc pod uwagę zależności (3.4) oraz (3.8), odporny odpowiednik niepewnego modelu $(PL1_U)$, w którym zbiór niepewności jest indywidualnie zdefiniowany dla każdego ograniczenia, można zapisać następująco:

$$(RC1): \left\{ \min_{\mathbf{x}} \{ \mathbf{c}^T \mathbf{x} : \tilde{\mathbf{A}} \mathbf{x} \leq \tilde{\mathbf{b}} \}, \forall \left([\bar{a}_i, \bar{b}_i] + \sum_{\ell}^{\mathcal{L}_i} \xi_{\ell} [a_i^{\ell}; b_i^{\ell}] : \xi \in \mathcal{Z}_i \right) \right\}_{(\tilde{\mathbf{A}}, \tilde{\mathbf{b}}) \in \mathbf{U}}$$

Analogicznie można zapisać sytuację, gdy zbiór niepewności dotyczy wszystkich ograniczeń:

$$(RC2): \left\{ \min_{\mathbf{x}} \{ \mathbf{c}^T \mathbf{x} : \tilde{\mathbf{A}} \mathbf{x} \leq \tilde{\mathbf{b}} \}, \forall \left([\bar{a}_i, \bar{b}_i] + \sum_{\ell}^{\mathcal{L}} \xi_{\ell} [a^{\ell}; b^{\ell}] : \xi \in \mathcal{Z} \right) \right\}_{(\tilde{\mathbf{A}}, \tilde{\mathbf{b}}) \in \mathbf{U}}$$

Odnosząc się do problematyki wyznaczania tras pojazdów, model $(RC1)$ można zinterpretować, jako występowanie indywidualnego zbioru niepewności dla każdego odcinka sieci z osobna. Oznaczałoby to, że możliwe wahania w wartościach charakterystyk ruchu na każdym z odcinków sieci drogowej są niezależne od siebie. Z założeń modelu $(RC2)$ wynika, że niepewność poszczególnych odcinków sieci są zależne od siebie i są powiązane wspólnym zbiorem niepewności danych. Wybór, który model powinien być przyjęty jest uzależniony od jakości posiadanych danych jak również interpretacji co jest modelowane. Czy niepewność danych, wynikająca z błędu pomiaru lub błędu prognozy, czy też niepewność objaśniająca możliwość wystąpienia nietypowych incydentów w sieci drogowej. W pierwszym przypadku wydaje się być zasadne stosowanie modelu $(RC1)$, w drugim modelu niepewności $(RC2)$.

Przedstawione modele odpornych odpowiedników są zdefiniowane w prostszej formie niż nieliniowa formuła modeli o niepewnych parametrach, jednakże nadal jest to struktura programowania pół-nieskończonego. Oznacza to, że pomimo skończonej liczby zmiennych, model zawiera nieskończoną liczbę ograniczeń, co prowadzi do wniosku, że jest to problem klasy NP-trudnej. Zgodnie z teorią optymalizacji odpornej [22], kwestię tą rozwiązuje się przez odpowiednie zdefiniowanie relacji w zbiorze niepewności \mathbf{U} . Poziom złożoności algorytmicznej modeli odpornych odpowiedników implikuje poziom złożoności algorytmicznej

zbioru niepewności. Gdy wypukły zbiór niepewności \mathbf{U} , jest dostępny obliczeniowo, to odporny odpowiednik też jest dostępny obliczeniowo. Aby zbiór niepewności posiadał cechę dostępności obliczeniowej, wprowadza się tzw. ekwiwalentną reprezentację problemu. W teorii optymalizacji oznacza, to zamianę oryginalnego, pół-nieskończonego zbioru niepewności na model zawierający skończoną liczbę ekwiwalentnych ograniczeń (szczegółowy opis oraz dowody zawarto w pracy [22]). W literaturze przedmiotu najpopularniejsze formy wprowadzania ekwiwalentnych reprezentacji problemu realizuje się przez zdefiniowanie zbioru perturbacji \mathcal{Z} , jako [92]:

- unormowaną przestrzeń zbioru przez normę typu suma (ang. Polyhedral uncertainty set),
- unormowaną przestrzeń zbioru przez normę euklidesową (ang. Ellipsoidal uncertainty set),
- unormowaną przestrzeń zbioru przez normę typu maksimum (ang. Box uncertainty set),
- unormowaną przestrzeń zbioru przez kombinację powyższych norm,
- uporządkowaną przestrzeń zbioru przez wypukłe, wielościenne stożki.

Zagadnienie wprowadzenia "właściwej" struktury zbioru niepewności wciąż jest wysoce teoretycznym zagadnieniem teorii optymalizacji odpornościowej. Jak wynika z wiedzy autora, dotychczasowe badania skupiają się nad kwestiami matematycznego modelowania, tak, aby nowe sformułowanie było "wygodne" z punktu widzenia optymalizacji oraz spełniało wysoki poziom prawdopodobieństwa, że ograniczenia modelu zostaną zachowane. Na chwilę obecną nie ma badań w kierunku analizy jak dana struktura zbioru niepewności, wpływa na rozwiązanie problemów rzeczywistych oraz jak ono wpływa na implementację danego rozwiązania w rzeczywistości. Z uwagi, że nie jest celem pracy rozważanie wspomnianych zagadnień, zakłada się, że zbiór niepewności danych proponowanego modelu będzie opisany przez tzw. "niepewność w ramach budżetu" (ang. budgeted uncertainty) [22, 28]. Jest to kombinacja normy typu suma i typu maksimum. Zagadnienie jest kolejnym etapem prac autora, które na tą chwilę wychodzących poza zakres pracy.

Pojęcie "niepewność w ramach budżetu" oznacza, że realizacja wartości zmiennej perturbacji ξ zależy od poziomu parametru sterującego konserwatywnością. Parametr poziomu konserwatywności jest budżetem niepewności, czyli innymi słowami, jak bardzo zakłada się w modelu, że parametry podlegają wahaniom. Szczegóły tej metody przedstawia następująca część podrzędnego rozdziału.

Definicja 6. "Niepewność w ramach budżetu" jest to przestrzeń zbioru perturbacji \mathcal{Z}^{NB} określona przez przecięcie $\|\cdot\|_{\infty} \leq 1$ oraz $\|\cdot\|_1 \leq \Gamma$, takie, że:

$$\mathcal{Z}^{NB} = \{\xi \in \mathbb{R}^{\mathcal{L}}: \|\xi\|_{\infty} \leq 1, \|\xi\|_1 \leq \Gamma\}$$

gdzie $\Gamma: 1 \leq \Gamma \leq |\mathcal{L}|$, jest budżetem niepewności.

"Niepewność w ramach budżetu" wykorzystuje kombinację normy typu maksimum oraz typu suma. Podejście to jest jednym z popularniejszych sposobów modelowania zbioru perturbacji. Jak wskazują dotychczasowe badania, transformacja ta cechuje się [22, 92]:

- wysokim prawdopodobieństwem zachowania wszystkich ograniczeń modelu,

- możliwością kontrolowania stopnia konserwatywności rozwiązania poprzez parametr Γ ,
- możliwością uzyskania rozwiązania o większym poziomie konserwatywności (porównując w innymi metodami),
- możliwością uzyskania modelu, którego sformułowanie jest w postaci programowania liniowego i jest ono dostępne obliczeniowo.

Kolejnym etapem rozważań jest wprowadzenie założenia o binarności danych, które przedstawiono w dalszej części tego podrozdziału.

3.3.2 PROGRAMOWANIE CAŁKOWITOLICZBOWE ODPORNE NA WAHANIA PARAMETRÓW MODELU MATEMATYCZNEGO

Do tego momentu rozważania na temat optymalizacji odpornej skupiały się wokół modeli, w których nie uwzględniono możliwości występowania zmiennych całkowitoliczbowych bądź jego szczególnego przypadku - zmiennych binarnych. Takie założenia przedstawiono w pracy [28], w której wykorzystano powyższe sformułowania, definicje oraz założenia. Model programowania mieszanego całkowitoliczbowego (ang. Mixed Integer Programming) można sformułować następująco:

$$(MIP): \min_{\mathbf{x}} \{ \mathbf{c}^T \mathbf{x} : \mathbf{A} \mathbf{x} \leq \mathbf{b}, \mathbf{x} \in [\mathbf{lb}, \mathbf{ub}] \wedge \mathbf{x} \in \mathbb{Z}, j \in \mathbf{NI} \} \quad (3.9)$$

gdzie: x_j jest wektorem n zmiennych decyzyjnych, gdzie pierwsza liczba n_i zmiennych jest całkowitoliczbową, a ich indeksy zawierają się w zbiorze: $\mathbf{NI} = \{1, \dots, n_i\}$, $\mathbf{NI} \subseteq \mathbf{N}$. Sens pozostałych oznaczeń jest taki sam jak w modelu (PL).

Bez straty ogólności, zakłada się, że niepewność wartości danych występuje w macierzy współczynników ograniczeń \mathbf{A} . Jeśli prawa strona ograniczeń jest poddana losowym perturbacjom, założenie to można rozszerzyć przyjmując, że prawa strona ograniczeń jest sformułowana, jako dodatkowa zmienna. Dla przykładu, jeśli w i -tym ograniczeniu prawa strona jest poddana niepewności, to można zmodyfikować model wprowadzając zmienną x_{n+1} oraz zapisując nowe ograniczenie jako: $a_{ij}x_j - b_i x_{n+1} \leq 0, x_j \in [lb_j, ub_j] \wedge x_{n+1} = 1$.

Model niepewności danych jest zdefiniowany w formie wielościanu i przedstawia się następująco (interpretacja oznaczeń jest taka sama jak w modelach (PL_u) oraz (RC2)): dla każdej wartości macierzy $a_{ij}, j \in \mathbf{N} \wedge i \in \mathbf{M}$, można zdefiniować losową, symetryczną, ograniczoną zmienną niezależną \tilde{a}_{ij} , której wahania wartości są ograniczone w zbiorze \mathbf{U} . Zatem matematyczny model całkowitoliczbowy o parametrach przedziałowych (MIP) można sformułować następująco:

$$(MIP_u): \{ \min_{\mathbf{x}} \{ \mathbf{c}^T \mathbf{x} : \tilde{\mathbf{A}} \mathbf{x} \leq \mathbf{b}, \mathbf{x} \in [\mathbf{lb}, \mathbf{ub}] \wedge \mathbf{x} \in \mathbb{Z}, j \in \mathbf{NI} \} \}_{\tilde{\mathbf{A}} \in \mathbf{U}} \quad (3.10)$$

Analogicznie jak w założeniu (3.4) zbiór niepewności modelu (MIP_u) jest zdefiniowany w formie afinicznej: każda zmienną \tilde{a}_{ij} przyjmuje wartości z przedziału $[\bar{a}_{ij} - \hat{a}_{ij}, \bar{a}_{ij} + \hat{a}_{ij}]$, gdzie \hat{a}_{ij} oznacza maksymalną odchyłkę od nominalnej wartości \bar{a}_{ij} . Korzystając z pojęcia zmiennej losowej opisującej możliwą perturbację, macierz współczynników ograniczeń przyjmie postać: $\tilde{a}_{ij} = \bar{a}_{ij} + \hat{a}_{ij} \eta_{ij}; \boldsymbol{\eta} \in \mathcal{Z}^{NB}$. Zmienna niezależna $\boldsymbol{\eta}$ jest losowa i przyjmuje

wartości z symetrycznego przedziału $[-1,1]$. Określa ona przeskalowaną wartość odchylenia, którą można zapisać: $\eta_{ij} = \frac{(\bar{a}_{ij} - \hat{a}_{ij})}{\hat{a}_{ij}}, j \in N \wedge i \in M$. Rozkład prawdopodobieństwa zmiennych losowych niezależnych η_{ij} jest nieznan - zakłada się, że przestrzeń zmian \mathcal{Z}^{NB} jest opisana przez "niepewność w ramach budżetu", czyli: $\mathcal{Z}^{NB} = \{\boldsymbol{\eta} \in \mathbb{R}^L: \|\eta_{ij}\|_{\infty} \leq 1; \|\eta_{ij}\|_1 \leq \Gamma_i, \forall i \in M\}$. Dla każdego ograniczenia wprowadza się parametr sterujący poziomem konserwatywności: $\boldsymbol{\Gamma} = [\Gamma_i], \forall i \in M$, który przyjmuje wartości z przedziału: $\boldsymbol{\Gamma} \in [0, |J_i|]$, gdzie $J_i = \{j | \hat{a}_{ij} > 0\}, \forall i \in M$. Innymi słowy oznacza to, jaka liczba współczynników macierzy ograniczeń będzie poddana wahaniom od wartości nominalnej. Jeśli $\Gamma_i = 0$ oznacza to, że w modelu nie założono uodpornienia na niepewność danych (sprowadza się to do modelu deterministycznego), z kolei, jeśli $\Gamma_i = |J_i|$ oznacza to, że w modelu założono maksymalny poziom uodpornienia na niepewność danych. Sprowadza się to wtedy do optymalizacji min-max, czyli wyboru najlepszego z najgorszych (podejście zaproponowane przez Soyster'a [126]).

Wykorzystując model (RC), definicję 6 oraz powyższe oznaczenie, odporny odpowiednik modelu (MIP_u), można zapisać [28]:

(3.11)

$$\begin{aligned}
 (RC_{MIP}): \quad & \min_{\mathbf{x}} \mathbf{c}^T \mathbf{x} \\
 p. o.: \quad & \sum_{j=1}^n \bar{a}_{ij} x_j + \max_{\mathbf{x}} \left\{ \sum_{j \in J_i} \hat{a}_{ij} |x_j| |\eta_{ij}| : \sum_{j \in J_i} \eta_{ij} \leq \Gamma_i, \eta_{ij} \in [-1,1], j \in J_i \right\} \leq b_i, \forall i \in M \\
 & lb_j \leq x_j \leq ub_j, \forall j \in N \\
 & x_j \in \mathbb{Z}, \quad \forall j \in NI
 \end{aligned}$$

Zaprezentowane sformułowanie problemu przez wewnętrzną maksymalizację jest w postaci nieliniowej, a więc może być ono niedostępne obliczeniowo. W cytowanej już pracy [28] zaproponowano ekwiwalentny model dla (RC_{MIP}), który uzyskano przez wykorzystanie silnego twierdzenia o dualności. Silne twierdzenie o dualności problemu programowania liniowego mówi, że: jeżeli jedno z zadań pierwotne lub dualne ma rozwiązanie, to drugie też ma rozwiązanie, a ich wartości funkcji celu są równe. Odporny odpowiednik liniowy problemu (RC_{MIP}) można zapisać w formie programowania liniowego:

$$\begin{aligned}
 (RC_{MIP}^e): \quad & \min_{\mathbf{x}} \mathbf{c}^T \mathbf{x} \\
 p. o.: \quad & \sum_{j \in N} \bar{a}_{ij} x_j + \theta_i \Gamma_i + \sum_{j \in J_i} \alpha_{ij}, \quad \forall i \in N \\
 & \theta_i + \alpha_{ij} \geq \hat{a}_{ij} y_j, \quad \forall i, j \in J_i \\
 & -y_j \leq x_j \leq y_j, \quad \forall j \in M \\
 & l_j \leq x_j \leq u_j, \quad \forall j \in M \\
 & \theta_i \geq 0, \quad \forall i \in N \\
 & \alpha_{ij} \geq 0, \quad \forall i \in M, j \in J_i \\
 & x_j \in \mathbb{Z}, \quad \forall j \in NI
 \end{aligned} \tag{3.12}$$

gdzie:

θ_i, α_{ij} - są dodatkowymi zmiennymi dualnego sformułowania wewnętrznej funkcji maksymalizacji w modelu (RC_{MIP}),

$y_j = |x_j^*|$ - jest dodatkową zmienną, która odpowiada optymalnemu rozwiązaniu x_j^* problemu (4.33)

Przedstawiony model jest ekwiwalentnym sformułowaniem (RC_{MIP}), co oznacza, że jest to aproksymacja oryginalnego problemu. Autorzy tego podejścia udowadniają, że uzyskane optymalne rozwiązanie x^* jest dopuszczalne, dla co najmniej $[\Gamma_i]$ współczynników ograniczeń \tilde{a}_{ij} , które podlegają perturbacjom losowym w i -tym ograniczeniu. W pozostałych przypadkach rozwiązanie x^* jest dopuszczalne dla pozostałych i -tych ograniczeń z wysokim poziomem prawdopodobieństwa. Poziom ten zależy od wybranej wartości Γ_i .

Podrozdział stanowi podłoże teoretyczne metodyki wprowadzania niepewności danych modelu w zagadnieniach wyznaczania tras pojazdów. W kolejnych podrozdziałach została przedstawiona koncepcja uwzględniania niepewności w problematyce wyznaczania tras pojazdów. Jednak zanim zostanie to opisane, mając zdefiniowane podłoże teoretyczne, można dokonać analizy aktualnego stanu wiedzy i badań naukowych w tym zakresie.

3.4 PRZEGLĄD WYBRANYCH MODELI UWZGLĘDNIAJĄCYCH NIEPEWNOŚĆ DANYCH W PROBLEMACH WYZNACZANIA TRAS POJAZDÓW

Poprzednie części pracy nakreślały i precyzowały obszar badawczy, którego dotyczy tematyka pracy. Jak się okazuje metody uodporniania modeli matematycznych na wahania wartości parametrów stały się w ostatnich latach na tyle popularne, że bardzo często można spotkać się z różnego rodzaju nadużyciami. Poniższy przegląd literatury dotyczy tylko tych prac, w których rozważano zastosowania metod i założeń teorii optymalizacji typu "robust" w zagadnieniach wyznaczania tras pojazdów (ang. Robust Vehicle Routing Problem - dalej RVRP). Pominięto prace, w których pojęcie "robust" było użyte, lecz dane rozważania nie odnosiły się do założeń tej odmiany optymalizacji, tylko do opisu cechy odporności danej metody czy uzyskanego rozwiązania. Dodatkowo poszukiwania ograniczono tylko do metod zakładających występowanie niepewności wartości danych w czasie przejazdu. Zawężając analizy tylko do tego rodzaju prac okazuje się, że liczba badań nad wykorzystaniem optymalizacji odpornej na wahania parametrów jest nieduża (z tendencją wzrostową).

3.4.1 POLSKIE BADANIA W ZAKRESIE MODELOWANIA NIEPEWNOŚCI DANYCH

W porównaniu do zasobów zagranicznych (podrozdział 3.4.2), liczba pozycji literatury polskiej podejmującej tematykę wyznaczania tras pojazdów jest niewielka. W źródłach bazy danych o zawartości polskich czasopism technicznych "BazTech" zostało odnalezionych tylko 19 pozycji literaturowych, które w swoich słowach kluczowych zawierają zwrot "vehicle routing problem" [21]. W popularnej, zagranicznej bazie danych "Web of Science" można odnaleźć zaledwie 49 pozycji literaturowych, które są autorstwa lub współautorstwa polskich naukowców i dotyczą wspomnianej tematyki [118]. Dotychczasowe prace nad zagadnieniem VRP głównie odnosiły się do prezentacji ogólnych modeli różnych wariantów problemów

VRP oraz propozycja ich efektywnego rozwiązywania²⁹, szczególnie wykorzystując heurystyki oparte na sztucznej inteligencji [17-20, 73, 99, 108, 123, 155, 156]. Część prac naukowych ma również charakter ogólny, gdzie autorzy przedstawiają problematykę VRP, jej charakterystykę oraz możliwe do wykorzystania metody rozwiązań, lecz brak w nich jakichkolwiek reprezentatywnych przykładów oraz weryfikacji zaprezentowanych założeń [11, 12, 71, 72, 154].

Jak wynika z powyższej analizy, żadna z przeglądanych polskich baz danych nie zawiera polskich badań naukowych z zakresu optymalizacji typu "robust" w zastosowaniu do problematyki wyznaczania tras pojazdów, co jest przedmiotem dysertacji. Jediną polską pracą, jaką udało się odnaleźć autorowi (nie korzystając z wymienionych baz danych), to praca [112], w której rozważano problem komiwojażera dla rozwożenia towarów pomiędzy piekarniami, w którym czas przejazdu był parametrem niepewnym. Niepewność modelu była zrealizowana przez określenie oczekiwanego oraz pesymistycznego czasu przejazdu pomiędzy obsługiwanyimi klientami (piekarniami), a celem optymalizacji był wybór wariantu najlepszego z najgorszych, tzw. optymalizacja min-max. W zaprezentowanym modelu przyjęto założenie, że klienci są połączeni bezpośrednio³⁰, przez co pominięto fakt, że każde połączenie jest zbiorem poszczególnych odcinków drogowych charakteryzujących się własnym poziomem niepewności i zmienności. Przyjęty model nie zakładał istnienia okien czasowych u klientów oraz przepływów rewersyjnych. Dodatkowo niepewność parametrów modelu została zaimplementowana w funkcji celu, co zgodnie z [22] jest to optymalizacja typu najlepszy z najgorszych.

Pierwszymi pracami, w których rozważano odporne modele w problemach VRP są dotychczasowe badania autora dysertacji. W pracy [83] rozważano problem rozwożenia i zbierania z ograniczeniem pojemnościowym pojazdu (ang. Pickup and Delivery Vehicle Routing Problem). Nie został jednak uwzględniony aspekt okien czasowych u klientów. W kolejnym artykule [81] przedstawiono koncepcję integracji odpornych modeli problemu najkrótszej ścieżki (ang. Robust Shortest Path Problem - dalej R-SPP) z problemem jednoczesnego zbierania i rozwożenia towarów przez pojazdy. We wspomnianej pracy również nie uwzględniono możliwych okien czasowych u klientów. Kolejną pracą z tej tematyki jest artykuł [7] ł. Autorzy tej pracy rozważają możliwości zastosowania problematyki wyznaczania odpornych tras pojazdów z oknami czasowymi w aspekcie całego systemu transportowo - logistycznego miasta.

3.4.2 ZAGRANICZNE BADANIA W ZAKRESIE MODELOWANIA NIEPEWNOŚCI DANYCH

Ostatnie dwie dekady pokazują, że zainteresowanie tematyką R-VRP na świecie rośnie i z roku na rok przybywa prac naukowych, w których rozważane jest 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 [118]. Można zauważyć tendencję wzrostową w liczbie tworzonych prac na jednostkę jednego roku - w 2013 roku powstało 12 prac, gdzie w drugiej połowie lat 90-tych średnio powstała 1 praca badawcza. Jednakże, należy wyraźnie podkreślić, że tylko część z wyszukanych prac odnosi

²⁹ Efektywne rozwiązywanie danego problemu jest rozumiane, jako te, które daje lepszy czas obliczeń w stosunku do pozostałych metod.

³⁰ Połączenie bezpośrednie zostało utworzone przy pomocy obliczenia najkrótszej ścieżki, przez co dla celów optymalizacji problemu komiwojażera można mówić o wirtualnym, bezpośrednim połączeniu klientów.

się do optymalizacji odpornej w zastosowaniu do problemów marszrutyzacji pojazdów. Jak to wspomniano we wstępie spora część wyszukanych prac zawiera słowo "robust", jednakże odporność rozwiązania nie została uzyskana przez wykorzystanie optymalizacji odpornej [24, 105, 109, 115, 116, 135, 137, 143]. Oznacza to, że zaproponowany model lub metoda sama w sobie nie wykorzystuje założeń optymalizacji odpornej, a tylko uzyskane rozwiązanie posiada cechy uodpornienia na zmienność parametrów modelu. Takie podejście sprowadza się bardziej do analizy wrażliwości rozwiązania, niż celowego uzyskania odpornego rozwiązania na niepewność parametrów 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 [31, 57, 121]. 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 praca nawiązuje do optymalizacji odpornościowej, dalszy przegląd literatury ograniczy się do zakresu optymalizacji typu robust oraz do założenia, że niepewność występuje w czasach przejazdu³¹. 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 [130], w którym przedstawiono matematyczny model problemu marszrutyzacji tylko z ograniczeniem pojemnościowym pojazdów (ang. Capacitated Vehicle Routing). Założenie modelu odnoszące się do niepewnych czasów przejazdów, sformułowano, jako maksymalną możliwą wartość czasu przejazdu na poszczególnych odcinkach, co powoduje, że uzyskane rozwiązanie jest 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 możliwych wahań wartości w czasach przejazdu.

W artykule [137] przedstawiono problematykę wyznaczania tras pojazdom uwzględniając tylko ograniczenie pojemnościowe floty. Odporny model problemu został rozwiązany przy pomocy teorii prymalno - dualnej. Podobnie jak w poprzednim przytoczonym artykule, autorzy również wykorzystali nierzeczywiste przykłady testowe - w tym przypadku popularne przykłady testowe Solomon'a [124], które zostały zmodyfikowane na własne potrzeby. W pracy podjęto próby stworzenia 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, że niepewność parametrów występuje na wirtualnych połączeniach pomiędzy klientami, czyli jest to zbyt duże uproszczenie warunków rzeczywistego procesu dystrybucji towarów.

Kolejną pracą, w której rozważano tylko problem wyznaczania tras z ograniczeniem pojemnościowym jest artykuł zaprezentowany w [68]. Autorzy tej pracy proponują swoje autor-

³¹ W literaturze można również odnaleźć prace o problematyce VRP, które odnoszą się do niepewności wielkości popytu klientów systemu dystrybucji lub niepewności okien czasowych klientów [152].

skie podejście do rozwiązywania zagadnień VRP, w których czas przejazdu jest zmienną losową nieopisaną rozkładem prawdopodobieństwa. Celem modelu jest odnalezienie ścieżek o najmniejszym koszcie wyrażanym czasem operacyjnym pojazdów. Cechy podejścia zostały określone na podstawie zmodyfikowanych przykładów Solomona, a wyniki zostały odniesione do podejścia stochastycznego. W artykule zaprezentowano również własny algorytm optymalizujący na bazie metody podziału i odcięć (ang. Branch-and-Cut). Podobnie jak w poprzednich pracach niepewność została przypisana do wirtualnych połączeń pomiędzy klientami.

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 pojazdów [8]. Do uwzględnienia niepewności danych wykorzystano metodę dwuetapowej optymalizacji odpornościowej (ang. Two Stage Robust Optimization). Podejście to zakłada, że część zmiennych niepewnych może dostosowywać swoje wartości do realizacji wartości parametrów niepewnych. 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 uwzględniane są wartości kosztów niezależne od czasu, zaproponowane podejście sprowadza się do optymalizacji odpornej (dowód na analogiczne twierdzenie jest zawarty w pracy [125]). Użycie dwuetapowej optymalizacji odpornej nie miało, więc większego uzasadnienia, ponieważ podejście to powinno być stosowane do problemów zależnych od czasu [22]. Dodatkowo, jak już wspomniano problem dotyczył transportu morskiego, a więc przeniesienie charakterystyki połączeń pomiędzy punktami w sieci morskiej na sieć drogową miasta jest niemożliwe.

W pracy [136] został zaprezentowany po raz pierwszy problem planowania tras pojazdów 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 (ang. Pickup and Delivery Pollution Routing Problem with Time Windows). Niepewność wartości parametrów modelu została wprowadzona w czterech aspektach: niepewność czasów przejazdów, niepewność czasu trwania obsługi, niepewność konsumpcji paliwa oraz niepewność wielkości emisji CO₂. Niestety poza bardzo zaawansowanym modelem matematycznym VRP, dalsza analiza w cytowanej pracy jest znacznie uproszczona. Brakuje informacji: o konstrukcji zbioru niepewności, o sposobie przejścia do ekwiwalentnego odpornego odpowiednika modelu VRP (brak wyjaśnień przyjętych oznaczeń), o wybranej metodzie optymalizacyjnej oraz o czasie obliczeń. Dodatkowo nie przedstawiono szczegółów założeń dla stworzenia przykładów obliczeniowych, czego konsekwencją jest niemożliwa weryfikacja założeń modelu oraz ewentualna porównywalność z innymi rozwiązaniami. Największa liczebność testowanych zbiorów to 12 klientów. Kwestia incydencji połączeń w sieci również została uproszczona do pełnej macierzy połączeń, co za tym idzie niepewność wartości została przypisana do wirtualnych łuków grafu.

Specyfikę rzeczywistej sieci drogowej, szczególnie sieci drogowej miasta, można zdefiniować w modelowaniu matematycznym przez połączenie dwóch problemów optymalizacyjnych: modelu typu robust problemu najkrótszej ścieżki (ang. Robust Shortest Path Problem)

i dowolnego problemu VRP. Podejście to zostało zaprezentowane w [48], 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). Model najkrótszej ścieżki został oparty o prace [102], 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 różnicę wartości spośród najgorszych możliwych różnic wartości od referencyjnej najkrótszej ścieżki. Model najkrótszej ścieżki został zaadaptowany do czasów przejazdów zależnych od czasu, które zmieniają się z zależności od jednostki czasu - wykorzystano go do obliczenia wszystkich możliwych kosztów pomiędzy wszystkimi parami klientów. Na tak przygotowanych danych wykonano optymalizację przebiegu tras pojazdów zgodnie z założonym modelem VRP. Przedstawiona metoda jest interesującym podejściem do wyznaczania tras pojazdom w rzeczywistych problemach transportowych. Jednakże zaproponowany sposób wyznaczania odpornej najkrótszej ścieżki jest nastawiony tylko i wyłącznie na minimalizację czasu przejazdu. Nie jest brana pod uwagę jakość obsługi klienta, która może być wyrażona poprzez wcześniejszy lub późniejszy przyjazd pojazdu do klienta, jak również pominięto aspekt pracy przewozowej pojazdów, która często jest wyrażana poprzez pokonany dystans przez pojazdy. Jak wynika z przeprowadzonych badań przez autora pracy, rzeczywiste firmy transportowe są zainteresowane minimalizacją większej liczby potencjalnych kosztów (szczegóły badań w rozdziale 4). Dodatkowo w modelu nie założono występowania elastycznych okien czasowych, co w rzeczywistym procesie dystrybucji towarów zazwyczaj nie ma miejsca. Ostatnia, najważniejsza kwestia to czas obliczeń. Autorzy pracy przedstawili zalety stosowania w oparciu o rzeczywisty przykład zawierający 30 klientów, dla których rozwiązanie problemu VRP zostało uzyskane w przeciągu 5 min, ze średnim poziomem zbieżności algorytmu 7,58%. Wynik świadczy o niskiej użyteczności w zastosowaniu takiego podejścia do rzeczywistości. Dodatkowo nie zostało to jasno opisane czy czas obliczeń odnosi się do obliczenia najkrótszych ścieżek razem z problemem VRP, czy tylko do optymalizacji problemu VRP.

3.5 WNIOSKI Z ROZDZIAŁU NR 3

Syntetyczne porównanie powyższych badań zaprezentowano w tabeli 3-2, w której odniesiono się również do założeń w proponowanym podejściu. Znak "+" oznacza, że dane założenie zostało uwzględnione w modelu; "-" że dane założenie nie zostało zawarte, "+/-" dana cecha została spełniona po części. Do oceny wzięto siedem cech, które miały odpowiedzieć na pytania: czy przyjęte dane zależą od czasu, gdzie została zaimplementowana niepewność wartości danych, jakie było kryterium funkcji, czy w modelu założono występowanie okien czasowych oraz przepływów wstecznych towarów, jakie dane przyjęto do weryfikacji modelu oraz czy metoda została porównana do innych podejść. W zaprezentowanej tabeli oraz w analizie powyżej często zwracano uwagę na miejsce implementacji niepewności i że losowość ta często jest uwzględniana w sposób bezpośredni. Szczegóły tego podejścia oraz jego wady przedstawiono w podrozdziale 4.2.2.

Tabela 3-2 Cechy podejść do problemu wyznaczania tras pojazdom z niepewnymi wartościami czasów przejazdów w literaturze przedmiotu.

Założenia modelu		Tan K. i inni (2007) [137]	Sungur I. i inni (2008) [130]	Donati A.V. i inni (2008) [49]	Tan K. i inni (2007) [137]	Han J. i inni (2013) [68]	Agra A. i inni (2013) [8]	Tajik N. i inni (2014) [136]	Propozowane podejście
Zależność danych od czasu		-	-	+	-	-	-	-	+
Implementacja niepewności w modelu	pośrednio	-	+	-	-	-	-	-	+
	bezpośrednio	+	-	+	+	+	+	+	-
Wielokryterialność celu		-	-	-	-	-	-	+	+
Okna czasowe	stałe	-	+	-	-	-	+	+	+
	elastyczne	-	-	-	-	-	-	-	+
Przepływ towarów	w przód	+	+	+	+	+	+	+	+
	wstecz	-	-	-	-	-	-	-	+
Przykład weryfikujący	testowy	+	+	+	+	+	+	+	+/-
	rzeczywisty	-	-	-	-	-	-	-	+/-
Porównanie z innymi metodami		-	-	-	-	+	-	-	+

Źródło: opracowanie własne na podstawie [8, 49, 68, 130, 136, 137].

Podsumowując powyższą analizę, poruszana tematyka jest niszowym obszarem badań, która w ostatnich latach zaczęła się cieszyć popularnością wśród naukowców na całym świecie. W większości dotychczasowych prac wskazywano zalety stosowania optymalizacji odpornej w problematyce VRP na przykładzie przypadków testowych (nierzeczywistych) i nie odnosząc ich do istniejących rozwiązań i innych metod wyznaczania tras pojazdom. Brakuje przejrzystych badań i analiz dotyczących przypadków rzeczywistych. W celach weryfikacji poprawności modeli oraz łatwej 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). W żadnej z przytoczonych prac nie poruszono kwestii: przepływu zwrotnego towarów tzw. logistyki rewersyjnej, która w ostatnich latach stała się punktem badań naukowców oraz aspektów występowania elastycznych okien czasowych. Konkludując, praca ma na celu uzupełnienie wskazanych braków w badaniach naukowych, poprzez zaproponowanie autorskiej metodyki wyznaczania tras pojazdów w rzeczywistych warunkach

miejskich uwzględniając niepewność wartości danych. Przyjęte założenia w modelu zostały oparte o informacje uzyskane od firmy transportowej.

4 MODEL OPTIMALIZACYJNY PROBLEMU WYZNACZANIA TRAS POJAZDÓW W OBSZARACH MIEJSKICH Z UWZGLĘDNIENIEM NIEPEWNOŚCI DANYCH

W pracy podjęto próbę formalnego opisu zagadnienia wyznaczania tras pojazdów w warunkach miejskich uwzględniając niepewność specyfikacji modelu. Prace nad właściwym zdefiniowaniem założeń modelu matematycznego sprowadziły się do dwóch głównych etapów: określenia specyfiki rozwożenia towarów w miastach w ujęciu praktyczno - teoretycznym oraz wprowadzenia niepewności wartości parametrów w modelu nominalnym.

Pierwszy element, to określenie dokładnej specyfiki problemu w oparciu: o wiedzę praktyczną firm transportowych oraz o wiedzę teoretyczną, która funkcjonuje w literaturze przedmiotu. Pozyskanie informacji na temat rzeczywistej specyfiki rozwożenia towarów w miastach dokonano poprzez wywiad z firmami transportowymi, które świadczą kompleksowe usługi transportowo - logistyczne na całym świecie³² oraz przez liczne rozmowy z kurierami rozwożącymi towary w mieście. Wnioski z uzyskanych informacji można przedstawić następująco (dotyczą one przesyłek kurierskich w dużych obszarach aglomeracyjnych):

1. Od 5 do 10% ogółu przesyłek jest realizowanych poza uzgodnionym z klientem oknem czasowym obsługi.
2. Średnia waga przesyłki wynosi od 18 do 20 kg, a średnia waga paczki: 10-12 kg,
3. Średni poziom wykorzystania ładowności pojazdów wynosi od 70% do 80%.
4. Zazwyczaj do jednego kuriera dziennie jest przypisanych od 40 do 60 doręczeń.
5. Średnia produktywność na trasie miejskiej to od 6 do 8 tzw. "stopów" na godzinę. Poprzez "stop" rozumiany jest konkretny adres, pod którym realizowana jest obsługa transportowa. Informacja ta przekłada się na średni czas obsługi klienta, który może przyjmować wartości z zakresu 8-10 min.
6. Ładowność pojazdów to 900 - 1200 kg. Biorąc pod uwagę przeciętną masę paczki, ładowność pojazdu w paczkach to 75 -120 kartonów.
7. Klienci są przypisani na stałe do wyznaczonych obszarów miasta, tzw. rejonów obsługi, które z kolei są przypisane do danego kierowcy. W sytuacjach wyjątkowych decyzję o przypisaniu klienta do kierowcy podejmuje dyspozytor.
8. Jeśli na danym obszarze obsługi jednego kierowcy wystąpi większa liczba klientów, obsługa tego obszaru jest realizowana przez kilku kierowców.
9. Przypisanie kierowcy do danego regionu jest aktualizowane, co 3 do 6 miesięcy. Nowy przydział jest tworzony na podstawie danych o wolumenie, produktywności kierowcy, czasie pracy kierowcy oraz przychodach samochodu. Kryterium w tym procesie decyzyjnym jest maksymalizacja wydajności oraz jakości doręczeń.

³² Ze względu na klauzulę poufności, do jakiej autor pracy się zobowiązał, nazwy firm nie mogą zostać ujawnione. Firmy ta w swojej ofercie posiadają usługi w zakresie transportu przesyłek lądowych, lotniczych, kolejowych oraz oceanicznych, jak również świadczy usługi kurierskie.

10. Jedna firma kurierska o średnim wolumenie przewożonych paczek, w ciągu dnia może wykorzystywać od 40 do 50 samochodów do obsługi dużego miasta. Firmy o bardzo wysokim liczbie zleceń może wykorzystywać nawet do 300 samochodów dziennie.
11. Trasa pojazdu i jej przebieg jest wyznaczana w oparciu o doświadczenie i intuicję kierowcy oraz/lub przy pomocy programów komputerowych.
12. Istotne kryteria dla firm przy realizacji transportu to: czas operacyjny, pokonany dystans, poziom obsługi klienta (wyrażony poprzez obsługę w wyznaczonym czasie), zużycie paliwa oraz emisja spalin.
13. Przy uwzględnianiu tylko kryterium czasu i dystansu, stosunek ważności między nimi wynosi: 75/25.
14. Przy uwzględnianiu tylko kryterium czasu i jakości obsługi, stosunek ważności między nimi wynosi: 60/40.
15. Istotny wpływ na czas realizacji danej trasy mają czynniki: wzmożonego ruchu drogowego, nieoczekiwane incydenty drogowe oraz czas obsługi klienta.

Kolejnym etapem było zweryfikowanie, jaki jest obecny stan wiedzy teoretycznej oraz odniesienie go do informacji uzyskanych od firm. Przeprowadzone badania i analizy umożliwiły zdefiniowanie autorskiego modelu dla problemu wyznaczania tras pojazdów zależnego od czasu, w którym uwzględniono elastyczne okna czasowe obsługi oraz wsteczne przepływy towarów (ang. Time-Dependent Pickup and Delivery Vehicle Routing Problem with Soft Time Windows - dalej TD-VRP-STW). Zaproponowano dwie wersje modelu: z dokładną liczbą pojazdów oraz z możliwą, maksymalną liczbą pojazdów. W pierwszym założono, że wszystkie pojazdy muszą być wykorzystane oraz uwzględniono cztery kryteria: minimalizację łącznego czasu trwania tras, łącznego pokonanego dystansu, użytych pojazdów oraz minimalizację wcześniejszych/późniejszych przyjazdów do klientów przez kierowców. Druga wersja modelu zakłada, że nie wszystkie pojazdy muszą być wykorzystane, a celem jest odnalezienie rozwiązania przy założeniu czterech kryteriów pierwszej wersji modelu oraz piątego kryterium minimalizacji liczby użytych pojazdów. Przedstawione modele były punktem wejściowym do dalszych rozważań nad sposobem implementacji niepewności danych reprezentujących czas przejazdu w sieci drogowej oraz czasu obsługi klienta.

4.1 DETERMINISTYCZNY PROBLEM WYZNACZANIA TRAS POJAZDÓW UWZGLĘDNIAJĄCY ELASTYCZNE OKNA CZASOWE ORAZ PRZEPIŁYWY REWERSYJNE TOWARÓW Z DANymi ZALEŻNYMI OD CZASU - TD-VRP-STW

4.1.1 SPECYFIKA I ZAŁOŻENIA OGÓLNE PROBLEMU TD-VRP-STW

W oparciu o pozyskane dane i informacje zostały zdefiniowane następujące założenia do stworzenia deterministycznego modelu dla problemu TD-VRP-STW (model ten będzie pełnił funkcję modelu nominalnego):

1. Model jest dedykowany do wyznaczania tras pojazdów na terenach miejskich, którego popyt i ewentualna podaż na usługi dystrybucyjne dotyczy towarów o niewielkich rozmiarach (tzw. paczki lub przesyłki kurierskie),

2. Celem procesu optymalizacyjnego jest wyznaczenie tras pojazdów mając na uwadze następujące kryteria:
 - a. łącznego czasu operacyjnego pojazdów (czas poruszania się pojazdów w sieci drogowej),
 - b. łącznego pokonanego dystansu przez pojazdy,
 - c. liczbę użytych pojazdów do realizacji obsługi transportowej,
 - d. łączny czas wcześniejszego rozpoczęcia obsługi klienta przez kierowcę,
 - e. łączny czas opóźnionego rozpoczęcia obsługi klienta przez kierowcę.
3. Istnieje możliwość uwzględnienia przepływów rewersyjnych towarów w miastach,
4. Obsługiwani klienci wymagają obsługi transportowej w wyznaczonym interwale czasowym,
5. Istnieje możliwość wcześniejszej/późniejszej obsługi klienta, wiąże się to z ponoszeniem dodatkowych przez firmę, np. kosztów lub obniżenie jakości obsługi,
6. Klienci są przypisywani do rejonów obsługi,
7. Wyznaczanie tras (sekwencji odwiedzanych klientów) jest dokonywane indywidualnie dla każdego z rejonów obsługi,
8. Obsługiwany towar jest opisany przez jedną cechę - jednostkę ładunkową,
9. Zastosowane pojazdy charakteryzują się podobną pojemnością wyrażoną przez cechę towaru,
10. Kierowcy i pojazdy rozpoczynają i kończą swoją pracę w tym samym punkcie.

Specyfika miejskiego systemu dystrybucji towarów jest istotnie różna od dystrybucji towarów na większych obszarach. Można tu wyszczególnić następujące cechy: losowe, dynamiczne zmiany parametrów ruchu, wysoka gęstość lokalizacji klientów na niewielkim obszarze oraz wysoki udział czasu obsługi klienta w stosunku do całkowitego czasu trwania trasy. Dodatkowo czas jazdy pojazdu pomiędzy klientami jest zdecydowanie mniejszy od szerokości potencjalnych okien czasowych obsługi, co powoduje, że problem wyznaczania tras pojazdów posiada cechy zbliżone do problemu harmonogramowania kierowców. Dedykowanym obszarem zastosowania proponowanych modeli i podejść jest system dystrybucji przesyłek kurierskich, jednak przyjęte dalsze założenia nie wykluczają możliwości przeniesienia ich na inne obszary. Kluczowym jest tylko i wyłącznie założenie o miejskiej obsłudze towarowej.

Wprowadzenie pięciu kryteriów przy poszukiwaniu rozwiązania optymalnego było zdefiniowane nie tylko przez uzyskane wyniki wywiadu z firmą, ale przede wszystkim przez charakterystykę procesu optymalizacji "odpornych" problemów VRP. Kryteria minimalizacji czasu wcześniejszego/późniejszego przyjazdu wynikają z warunków rzeczywistej realizacji dystrybucji przesyłek kurierskich. Założenie sztywnych okien czasowych jest właściwe tylko w symulacjach komputerowych, w rzeczywistości kurier może przyjechać do klienta wcześniej lub później. Nie zawsze wpłynie to na realizację dalszych przesyłek (trasa nadal jest kontynuowana), tylko na wizerunek firmy, poziom satysfakcji klienta i poziom świadczonych usług. Z tego powodu, uwzględnienie tzw. elastycznych okien czasowych jest bliższe rzeczywistości (założenia 4 i 5).

Obecnie w towarowym systemie miasta można zaobserwować trend odbierania paczek/przesyłek od klientów bezpośrednio przez kurierów. Są to usługi typu "zamów kuriera". W tych usługach kurier odwiedza klientów, od których odbiera paczkę, co tworzy wsteczny (rewersyjny) przepływ towaru w stosunku do klasycznej dystrybucji towarów. W proponowa-

nym modelu założono, że zbieranie towarów od klientów będzie odbywać się równoległe z rozwożeniem towarów. Dany klient może charakteryzować się popytem na towary (przepływ towarów w przód) i/lub może charakteryzować się podażą na towary (przepływ towarów wstecz).

Założenia 6 oraz 7 sugerują, że problem wyznaczania tras pojazdów nie jest rozpatrywany globalnie, np. w skali całego miasta, lecz tylko w obrębie rejonów obsługi, które są obsługiwane przez przypisanych do nich kurierów. Jest to spowodowane praktycznymi aspektami pracy kurierów tj.: dobra znajomość specyfiki danego obszaru przez kierowcę oraz unikanie przypisywania do danego kierowcy klientów rozproszonych przestrzennie. Dzięki takiej organizacji pracy kurierów, globalny problem decyzyjny obsłużenia wszystkich klientów w mieście jest podzielony na mniejsze problemy wyznaczania tras w obrębie każdego rejonu obsługi. Często może się to sprowadzić do wielokrotnego problemu komiwojażera. Jednak ograniczenie się tylko do zagadnienie TSP będzie niewystarczające. Jak wynika z przeprowadzonych rozmów autora z kurierami, często zdarza się tak, że liczba klientów lub ich specyfika wymaga użycia większej liczby kierowców niż jeden. Z tego powodu w dalszych rozważaniach zakłada się, że dla każdego rejonu jest zdefiniowany problem klasy VRP.

Obsługiwany towar nie jest sprecyzowany, co do ilości asortymentowej. Charakterystyka towaru może być opisana poprzez jedną cechę: masę, objętość, ilość lub jednostkę ładunkową. Oznacza to, że obsługiwane towary nie muszą być jednorodnie asortymentowo. W przesyłkach kurierskich, zazwyczaj, operuje się jednostką ładunkową, która posiada dopuszczalną, maksymalną masę, np. paczka do 20kg. W ten sposób można operować wielo-towarowym przepływem. Pominięcie innych cech towarów tj. wymiary nie powoduje niewłaściwego opisu procesu, ponieważ możliwe jest sprowadzanie wielu cech do jednej zastępczej (np. paczka, karton, itd.).

Założenie 9 wynika z dwóch poprzednich - skoro rozważany jest obszar obsługi indywidualnie, to pojazdy obsługujące dany rejon będą charakteryzować się taką samą pojemnością. Wynika to z charakterystyki i dostępności transportowej danego obszaru, np. do obsłużenia historycznych obszarów należy stosować tylko i wyłącznie nie duże pojazdy o wysokich normach emisyjnych. Nie oznacza to, że w całościowym ujęciu procesu planowania tras pojazdów pojazdy są pojemnościowo homogeniczne.

Ostatni warunek zakłada, że struktura systemu dystrybucji jest zcentralizowana, którego centrum jest baza logistyczna, magazyn lub centrum dystrybucji towarów. Wszystkie trasy pojazdów muszą rozpocząć się i zakończyć w tym samym miejscu.

Powyższe ogólne założenia były podstawą do sformułowania matematycznego deterministycznego modelu dla problemu TD-VRP-STW w dwóch wersjach: ze stałą liczbą pojazdów oraz z maksymalną liczbą pojazdów. Na podstawie sformułowanego modelu matematycznego przeprowadzono charakterystykę założeń oraz wskazano możliwe kierunki działań w celu zdefiniowania wersji uwzględniającej niepewność danych.

4.1.2 CZTEROKRYTERIALNE SFORMUŁOWANIE PROBLEMU TD-VRP-STW

W oparciu o teorię grafów zakłada się, że sieć drogowa jest zdefiniowana w postaci skierowane grafu G składającego się z uporządkowanej pary:

$$G = \langle VS, AS \rangle$$

gdzie:

$VS = \{1, 2, \dots, vs\}$ jest zbiorem indeksów vs wierzchołków grafu, reprezentujących zbiór węzłów transportowych. Przez węzeł transportowy rozumiane jest rzeczywiste skrzyżowanie, połączenie dróg, jak również lokalizacja klienta, tworząca dodatkowy węzeł połączony z pozostałymi,

$AS = \{(i, j): i \neq j \wedge i, j \in VS \times VS\}$ oznacza zbiór skierowanych łuków grafu, o interpretacji bezpośredniego połączenia pomiędzy węzłami sieci drogowej tj. odcinki drogowe.

Zbiór AS reprezentowany jest przez uporządkowane pary wierzchołków (i, j) , w której i jest tak zwanym poprzednikiem wierzchołka j (źródłem), a wierzchołek j jest następnikiem i (celem). W celu zdefiniowania wszystkich połączeń ze zbioru AS przyjmuje się binarne odwzorowanie na iloczynie kartezjańskim takie, że: $\zeta: VS \times VS \rightarrow \{0, 1\}$, gdzie wielkość $\zeta(i, j) = 1, \forall i, j \in VS$, gdy między węzłami (i, j) występuje połączenie transportowe, w przeciwnym wypadku wielkość $\zeta(i, j) = 0, \forall i, j \in VS$. Zdefiniowanie reprezentacji sieci drogowej wynika z faktu, że dalsze rozważania, zaprezentowane modele i koncepcje bazują na rzeczywistej sieci drogowej.

Deterministyczny model matematyczny dla zagadnienia TD-VRP-STW można przedstawić następująco: dany jest skierowany graf GP , zdefiniowany przez uporządkowaną parę:

$$GP = \langle VP, AP \rangle$$

gdzie:

$VP = \{1, 2, \dots, vp\}$ jest zbiorem indeksów vp wierzchołków, reprezentujących zbiór klientów, przy czym $vp = \{1\}$ oznacza magazyn, z którego rozpoczynają się i kończą się trasy pojazdów. Dodatkowo zachodzi relacja: $VP \subseteq VS$.

$AP = \{(i, j): i \neq j \wedge i, j \in VP \times VP\}$ oznacza zbiór skierowanych łuków grafu, o interpretacji bezpośredniego połączenia pomiędzy węzłami sieci drogowej.

Zbiór AP reprezentowany jest przez uporządkowane pary wierzchołków (i, j) . W celu zdefiniowania wszystkich połączeń ze zbioru AP przyjmuje się binarne odwzorowanie na iloczynie kartezjańskim takie, że: $\zeta^P: VP \times VP \rightarrow \{0, 1\}$, gdzie wielkość $\zeta^P(i, j) = 1, \forall i, j \in VP$, gdy między węzłami (i, j) występuje połączenie transportowe, w przeciwnym wypadku wielkość $\zeta^P(i, j) = 0, \forall i, j \in VP$. W zależności od interpretacji połączenie to może być rozumiane, jako: najkrótsza ścieżka pomiędzy wierzchołkiem i , a wierzchołkiem j lub rzeczywisty odcinek drogowy.


Mając na uwadze dość istotną cechę sieci transportowej, jaką jest dynamika zmian jej charakterystyk m.in. w zależności od pory dnia, tygodnia, miesiąca, czy roku, zasadne jest wprowadzenie tej dynamiki do modelu. Można to zrealizować np. przy pomocy dyskretyzowania czasu poprzez interwały czasowe. W każdym interwale wartości poszczególnych charakterystyk mogą przyjmować różne wartości. Niech zbiór T będzie oznaczał zbiór indeksów kolejnych interwałów czasowych: $T = \{\tau: \tau = 1, \dots, |T|\}$. Początek i koniec danego interwału

są opisane poprzez wartość: $U_\tau \in \mathbb{R}^+, \forall \tau \in \mathbf{T} \cup \{0\}$. Wartości te definiują zbiór \mathbf{TI} przedziałów jednostronnie domkniętych zdefiniowany następująco:

$$\mathbf{TI} = \langle ti_\tau \rangle = \{(U_0, U_1], \dots, (U_{\tau-1}, U_\tau], \dots, (U_{|T|-1}, U_{|T|}]\}$$

Każdemu łukowi (i, j) ze zbioru \mathbf{AP} przyporządkowano koszt w postaci macierzy: $\mathbf{TT} = [tt_{ij\tau}]$, przy czym $tt_{ij\tau} \geq 0, \forall (i, j) \in \mathbf{AP} \wedge \forall \tau \in \mathbf{T}$, który reprezentuje czas przejazdu na połączeniu (i, j) w danym τ interwale czasowym. Zakłada się, że czas przejazdu na każdym z łuków grafu jest funkcją czasu: $[tt_{ij}(\tau)] \equiv [tt_{ij\tau}]$, gdzie $tt_{ij}(\tau)$ jest funkcją skokową czasu przejazdu łuku (i, j) zależną od wartości τ interwału czasowego. Dodatkowo każdemu łukowi (i, j) ze zbioru \mathbf{AP} przyporządkowano koszt w postaci macierzy: $\mathbf{DD} = [dd_{ij}]$, przy czym $dd_{ij} \geq 0, \forall (i, j) \in \mathbf{AP}$ która definiuje odległość pomiędzy węzłami (i, j) .

Dyskretyzacja czasu przejazdu dzieli dzień na $|T|$ liczbę interwałów, w których czas przejazdu może być różny. Założenie to przedstawia rysunek 4.1. Funkcja czasu przejazdu odcinka (i, j) została podzielona na cztery interwały $|T| = 4$, którego granice wyznaczają wartości $U_\tau: \tau = 0, 1, 2, 3, 4$.



Rysunek 4.1. Skokowa funkcja czasu przejazdu dla odcinka (i, j) z czterema interwałami czasu $M_{ij}=4$.

Źródło: opracowanie własne na podstawie [96]

W przypadku rozważania czasu przejazdu, jako funkcji skokowej w procesie optymalizacji, ważną kwestią jest spełnianie zasady FIFO (ang. First-In First-Out) przez uzyskaną ścieżkę. Model posiadający własność FIFO zakłada, że jeśli dowolny pojazd odjedzie od i -tego klienta w kierunku j -tego klienta w porze dnia τ , to inny pojazd wyjeżdżający o czasie $\tau + \varepsilon, \varepsilon > 0$ poruszający się po tej samej trasie, zawsze przyjedzie później do j -tego klienta [55]. Na etapie propozycji modelu deterministycznego zależnego od czasu, zasada FIFO może nie być spełniona. Jednak w dalszych rozważaniach zakłada się, że czas przejazdu będzie określony losowym zakresem zmienności, a celem optymalizacja będzie wybór scenariusza najlepszego z najgorszych przy zadanym poziomie niepewności. Wobec czego własność FIFO będzie spełniona. Analogiczny wniosek został zaprezentowany w pracy [129], gdzie rozważano stochastyczny model VRP.


Magazyn posiada flotę K homogenicznych pojazdów, które posiadają ładowność maksymalną wyrażoną przez Q . Pozostałe wierzchołki grafu $\mathbf{VP}_c = \mathbf{VP} \setminus \{1\}$ są utożsamiane ze zbiorem klientów, którzy wymagają obsługi transportowej w postaci dostarczenia oraz/lub odebrania pewnej ilości towarów. Każdy wierzchołek $i \in \mathbf{VP}$ charakteryzuje się nieujemnym

popytym na towary $\mathbf{d} = [d_i]$, nieujemną podażą na towary $\mathbf{s} = [s_i]$ oraz nieujemnym czasem obsługi $\mathbf{st} = [st_i]$. Dla magazynu zakłada się, że $d_1 = s_1 = st_1 = 0$.

Każdy wierzchołek posiada przypisane okno czasowe obsługi: $[e_i, l_i], \forall i \in VP$, oznaczający interwał czasowy, w którym klient musi być obsłużony. Wartości $[e_i, l_i]$ oznaczają, odpowiednio, najwcześniejszy oraz najpóźniejszy możliwy czas rozpoczęcia obsługi transportowej. Zbiór okien czasowych obsługi można zdefiniować poprzez:

$\mathbf{TW} = [tw_i] = \langle [e_1, l_1], \dots, [e_i, l_i], \dots, [e_n, l_n] \rangle$. Dodatkowo zakłada się możliwość zaakceptowania przez klienta wcześniejszego lub późniejszego rozpoczęcia obsługi, innego niż wynika to z wartości par zbioru \mathbf{TW} , jednakże fakt ten jest obciążony ponoszeniem dodatkowego kosztu. Możliwość wcześniejszego/późniejszego przyjazdu do klienta jest ograniczona rozszerzonym oknem czasowym wyrażonym przez zbiór:

$\mathbf{TW}^\# = [tw_i^\#] = \langle [e_1^\#, l_1^\#], \dots, [e_i^\#, l_i^\#], \dots, [e_n^\#, l_n^\#] \rangle$, przy założeniu, że: $e_i^\# \leq e_i \wedge l_i \leq l_i^\#$. Pary wartości ze zbioru $\mathbf{TW}^\#$ w literaturze przedmiotu funkcjonują, jako pojęcie elastycznego okna czasowego (ang. Soft Time Windows). Poza tym oknem czasowym obsługa klienta jest niedozwolona. Charakterystykę takiego sformułowania okien czasowych u klientów przedstawia rysunek 4.2. Jeśli kierowca rozpocznie obsługę klienta w przedziale $[e_i, l_i]$ to do wartości funkcji kryterialnej zostanie dodana wartość: $F(\tau) = 0$. Z kolei jeśli czas rozpoczęcia obsługi znajdzie się w przedziale: $[e_i^\#, l_i^\#]$, to zostanie dodana do funkcji kryterialnej dodatkowa wartość $F(\tau)$, która może być interpretowana jako kara za nieterminowy czas obsługi. Wartość kary za wcześniejsze rozpoczęcie obsługi może być inna, niż wartość kary za późniejszy przyjazd do klienta. Zakłada się, że okno czasowe magazynu przyjmuje wartości: $[e_1, l_1] = [e_1^\#, l_1^\#] = [E, L]$, gdzie E i L oznaczają odpowiednio najwcześniejszy możliwy wyjazd pojazdów z magazynu i najpóźniejszy możliwy powrót pojazdów do magazynu.



Rysunek 4.2 Funkcja kary oraz charakterystyka elastycznego okna czasowego dla i-tego klienta.

Źródło: opracowanie własne.

Wierzchołek - magazyn $vp = 1$ zostanie zdefiniowany w następujący sposób: będzie funkcjonować jako wierzchołek startowy tzn. wszystkie łuki "wchodzące" do VP_1 zostaną usunięte. Dodatkowo zostaną utworzone wirtualne wierzchołki w liczbie równej liczbie po-

jazdów, czyli: $VP_K = VP \cup \{VP_{n+1}, VP_{n+2}, \dots, VP_{n+K}\}$, które będą pełniły rolę magazynów powrotnych dla każdego z pojazdów indywidualnie. Do każdego z wirtualnych wierzchołków zostaną przypisane łuki "wchodzące" do wierzchołka VP_1 . Dzięki takiej operacji każdy pojazd rozpocznie trasę w wierzchołku VP_1 , a zakończy ją we własnym magazynie powrotnym. W analogiczny sposób zostaną rozszerzone macierze odległości $DD \rightarrow DD_K$ oraz macierze czasów przejazdów $TT \rightarrow TT_K$. Nowy, powiększony graf można zapisać, jako: $GP_K = \langle VP_K, AP_K \rangle$ gdzie AP_K jest zbiorem łuków powiększonym zgodnie z opisem powyżej.

Problem wyznaczania tras pojazdów TD-VRP-STW został sformułowany w postaci programowania całkowitoliczbowego (ang. Mixed Integer Programming) i rozszerzony o prace własne autora [7] oraz wykorzystujące badania przedstawione w pracach [55] [96] [127] [145]):

W modelu występują cztery zmienne decyzyjne, które można zdefiniować następująco:

$x_{ij\tau} \in \{0,1\}$ - zmienna binarna określająca, czy dany łuk (i,j) znajduje się w rozwiązaniu w okresie τ ,

$df_{ij} \geq 0$ - zmienna określająca ilość towaru rozwożonego, znajdującego się w pojeździe przejeżdżającym przez łuk (i,j) - przepływ towarów w przód,

$sf_{ij} \geq 0$ - zmienna określająca ilość towaru zbieranego, znajdującego się w pojeździe przejeżdżającym przez łuk (i,j) - przepływ rewersyjny,

$ta_i \geq 0$ - oznacza czas przyjazdu pojazdu do i-tego klienta - jest to moment rozpoczęcia obsługi klienta. Zmienne te tworzą wektor zmiennych, oznaczony: $\mathbf{Ta} = [ta_i], \forall i \in VP_K$

$f_i \geq 0$ - wartość i-tego kryterium cząstkowego funkcji celu,

Funkcja kryterialna jest sumą cząstkowych kryteriów, której zapis przedstawia się:

$$(VRP1^T): \min_{f_i} \sum_{i=1}^4 \delta_i f_i \quad (4.1)$$

Ograniczenia wynikające z kryteriów cząstkowych:

$$f_1 \geq \sum_{\tau \in T} \sum_{(i,j) \in AP_K} x_{ij\tau} \cdot tt_{ij\tau} \quad (4.2)$$

$$f_2 \geq \sum_{(i,j) \in AP_K} (dd_{ij} \cdot \sum_{\tau \in T} x_{ij\tau}) \quad (4.3)$$

$$f_3 \geq \sum_{i \in VP_c} (e_i - ta_i)^+ \quad (4.4)$$

$$f_4 \geq \sum_{i \in VP_c} (ta_i - l_i)^+ \quad (4.5)$$

Ograniczenia definiujące poprawność przepływu:

$$\sum_{\tau \in T} \sum_{i \in VP} x_{ij\tau} = 1, \quad \forall j \in VP_K \setminus \{1\} \quad (4.6)$$

$$\sum_{\tau \in T} \sum_{j \in VP_K \setminus \{1\}} x_{ij\tau} = 1, \quad \forall i \in VP_c \quad (4.7)$$

$$\sum_{\tau \in T} \sum_{j \in VP_c} x_{1j\tau} = K \quad (4.8)$$

Ograniczenia pojemnościowe:

$$\sum_{j \in VP_k} df_{ji} - \sum_{j \in VP_k} df_{ij} = d_i, \quad \forall i \in VP_c \quad (4.9)$$

$$\sum_{j \in VP_k} sf_{ij} - \sum_{j \in VP_k} sf_{ji} = s_i, \quad \forall i \in VP_c \quad (4.10)$$

$$df_{ij} + sf_{ij} \leq (Q - \max\{0, sf_j - df_j, df_i - sf_i\}) \cdot x_{ij\tau}, \quad \forall (i, j) \in AP_K, \forall \tau \in T \quad (4.11)$$

Ograniczenia związane z oknami czasowymi:

$$ta_i + st_i + tt_{ij\tau} - ta_j - (1 - x_{ij\tau}) \cdot b_{1ij} \leq 0, \quad \forall i \in VP; \forall j \in VP_k \setminus \{1\}; i \neq j; \forall \tau \in T \quad (4.12)$$

$$ta_i + st_i + tt_{ij\tau} - ta_j - (x_{ij\tau} - 1) \cdot b_{1ij} \geq 0, \quad \forall i \in VP; \forall j \in VP_k \setminus \{1\}; i \neq j; \forall \tau \in T \quad (4.13)$$

$$e_i^\# \leq ta_i \leq l_i^\#, \quad \forall i \in VP_K \quad (4.14)$$

$$\left. \begin{array}{l} ta_i + x_{ij\tau} \cdot B2 \leq U_\tau + B2 \\ ta_i + U_{\tau-1} \cdot x_{ij\tau} \geq 0 \end{array} \right\} \forall i \in VP; \forall j \in VP_k \setminus \{1\}; i \neq j; \forall \tau \in T \quad (4.15)$$

Natura zmiennych:

$$x_{ij\tau} \in \{0,1\}, \quad \forall (i, j) \in AP_K \quad (4.16)$$

$$df_{ij} \in \mathbb{R}^+, \quad \forall (i, j) \in AP_K$$

$$sf_{ij} \in \mathbb{R}^+, \quad \forall (i, j) \in AP_K$$

$$ta_i \in \mathbb{R}^+, \quad \forall i \in VP_K$$

$$f_i^{SP} \in \mathbb{R}^+, i = 1, \dots, 4$$

Zgodnie z założeniami celem problemu (VRP^T) jest minimalizacja pięciu pod-kryteriów: łącznego czasu, łącznego dystansu, łącznego czasu dla zbyt wczesnego przyjazdu pojazdów do klientów, łącznego czasu dla zbyt późnego przyjazdu pojazdów do klientów oraz liczby pojazdów użytych w rozwiązaniu. W związku z tym, że poszczególne elementy charakteryzują się różnymi jednostkami bezpośrednio, dodawanie ich jest niemożliwe. Funkcja kryterialna (4.1) posiada parametry $\delta_1, \delta_2, \delta_3, \delta_4$, które można interpretować jako jednostkowy, odpowiednio: koszt jednej wozogodziny, koszt jednego wozokilometra, koszt związany z wcześniejszym przyjazdem pojazdu do klienta oraz koszt związany z późniejszym przyjazdem pojazdu do klienta. Tak sformułowany cel umożliwia sumowanie poszczególnych kryteriów cząstkowych, ponieważ po przemnożeniu przez wskazane parametry każdy będzie posiadał jedną wspólną jednostkę, wyrażoną np. poprzez obowiązującą walutę.

Ograniczenia od (4.2) do (4.5) wyrażają sposób realizacji w procesie optymalizacji poszczególnych kryteriów cząstkowych, czyli:

- Pierwsze kryterium cząstkowe - minimalizacja łącznego operacyjnego czasu poruszania się pojazdów w sieci,
- Drugie kryterium cząstkowe - minimalizacja pokonanego dystansu przez wszystkie pojazdy,
- Trzecie kryterium cząstkowe - minimalizacja łącznego czasu oczekiwania u klientów. Kryterium to ma na celu zminimalizowanie czasu oczekiwania kierowców u klientów na otwarcie się okna czasowego obsługi,
- Czwarte kryterium cząstkowe - minimalizacja łącznego czasu opóźnionej obsługi klienta przez kierowcę. Czas opóźnienia można interpretować, jako abstrakcyjną karę dla firmy transportowej, w związku z nieobsłużeniem klienta w preferowanym czasie obsługi. Im większy będzie łączny czas opóźnienia, tym poziom usług realizacji danej trasy będzie mniejszy.

Poprawność przejazdu pojazdów w sieci zapewniają ograniczenia (4.6) - (4.7). Użycie w rozwiązaniu K -tej liczby pojazdów gwarantuje ograniczenie (4.8). Właściwy przepływ towarów zapewniają ograniczenia: (4.9) - przepływ towarów w przód (popyt) oraz (4.10) - przepływ towarów w tył. Na każdym etapie wyznaczonej trasy pojazdów, pojemność nie może zostać przekroczona, co przedstawia nierówność (4.11). Ograniczenia związane z oknami czasowymi zostały zapisane przy użyciu tzw. "dużej liczby". Takie sformułowanie umożliwia czasową aktywację i dezaktywację ograniczenia (4.12) oraz (4.13), w zależności od bieżącego rozwiązania metody optymalizacyjnej. Oba ograniczenia powstały w wyniku zapewnienia, że nie powstaną czasy oczekiwania w wierzchołkach sieci, podczas realizacji trasy. Formalnie takie ograniczenia można zapisać w postaci jednej równości jednak, mając na uwadze charakterystykę procesu optymalizacji, właściwszym jest zastąpienie ograniczenia równościowego, dwoma nierównościami, które wyrażają to samo. Macierz $\mathbf{B1} = [b_{1_{ij}}]$ zawiera tzw. "duże liczby", które można rozumieć, jako maksymalny możliwy czas zakończenia ścieżki pomiędzy parą punktów (i, j) plus maksymalny czas przejazdu w sieci na odcinku (i, j) plus maksymalny czas obsługi i -tego klienta. Ograniczenia (4.14) zakłada, że czas przyjazdu do dowolnego wierzchołka sieci znajduje się w granicach elastycznego okna czasowego. Tymczasowe ograniczenia (4.15) zapewniają, że właściwa wartość czasu przejazdu będzie brana w obliczaniu najkrótszej ścieżki. Ideę tego warunku można przedstawić następująco: jeśli $x_{ij\tau} = 1$, to czas przyjazdu do i -tego klienta powinien zawierać się w przedziale: $U_{\tau-1} \leq t_i \leq U_{\tau}, \forall(i, j, m)$. Parametr $B2$ jest "dużą liczbą", która oznacza maksymalny czas zakończenia każdej trasy. W przypadku, gdy czas ten jest taki sam dla każdego pojazdu, można go utożsamić z końcem pracy magazynu i wtedy będzie on wyrażony poprzez: $B_2 = L$. Ostanie ograniczenia wskazują na charakterystykę zmiennych oraz ich zakres zmienności w przestrzeni.

W pracy [67] zaprezentowano możliwość zawężenia ograniczeń (4.16) dotyczących nieujemności zmiennych opisujących przepływ towarów na łukach. Ograniczenia te można zastąpić ściślejszym sformułowaniem :

$$d_j x_{ij\tau} \leq df_{ji} \leq (Q - d_i) x_{ij\tau}, \forall(i, j) \in \mathbf{AP}_K, \forall \tau \in T \quad (4.17)$$

$$s_i x_{ij\tau} \leq df_{ij} \leq (Q - s_j) x_{ij\tau}, \forall(i, j) \in \mathbf{AP}_K, \forall \tau \in T \quad (4.18)$$

4.1.3 PIĘCIOKRYTERIALNE SFORMUŁOWANIE PROBLEMU TD-VRP-STW

Możliwe jest również uogólnienie warunku o stałej liczbie pojazdów przez wprowadzenie założenia o stosowaniu, co najwyżej K -tej liczby pojazdów. Modyfikacja takiego założenia umożliwi sprawdzenia czy istnieje rozwiązanie, w którym można użyć mniej pojazdów niż to się zakłada przed procesem optymalizacji. W tym celu należy zmodyfikować ograniczenia (4.7) oraz (4.9) jak również należy dodać kolejne kryterium cząstkowe - minimalizację liczby użytych pojazdów. Przyjmując oznaczenia modelu ($VRP1^T$), drugą wersję problemu TD-VRP-STW można zapisać następująco:

$$(VRP2^T): \min \sum_{i=1}^5 \delta_i f_i \quad (4.19)$$

Przy ograniczeniach wynikających z kryteriów cząstkowych od (4.2) do (4.5) oraz:

$$f_5 \geq \sum_{\tau \in T} \sum_{j \in VP_c} x_{1j\tau} \quad (4.20)$$

Ograniczenia definiujące poprawność przepływu (4.7) oraz:

$$\left. \begin{array}{l} \sum_{\tau \in T} \sum_{i \in VP} x_{ij\tau} = 1, \quad \forall j \in VP_c \\ \sum_{\tau \in T} \sum_{i \in VP} x_{ij\tau} \leq 1, \quad \forall j \in VP_k \setminus VP_c \end{array} \right\} \quad (4.21)$$

$$\left. \begin{array}{l} \sum_{\tau \in T} \sum_{j \in VP_c} x_{1j\tau} \geq 1 \\ \sum_{\tau \in T} \sum_{j \in VP_c} x_{1j\tau} \leq K \end{array} \right\} \quad (4.22)$$

Wraz z pozostałymi ograniczeniami modelu ($VRP1^T$), czyli od (4.9) do (4.16).

Ograniczenie (4.20) jest zapisem piątego kryterium - minimalizacji użytych pojazdów. Parametr δ_5 oznacza jednostkowy koszt użycia jednego pojazdu do obsługi transportowej. Ograniczenia (4.21) oraz (4.22) są modyfikacją ograniczeń, odpowiednio: (4.6) i (4.8), dzięki której w problemie można użyć, co najwyżej K -tą liczbę pojazdów.

Kwestią mogącą budzić wątpliwości w zaproponowanych wersjach zapisu problemu wyznaczania tras jest konstrukcja funkcji kryterialnej. Z ekonomicznego punktu widzenia, użycie jednostkowych kosztów zdefiniowanych przez parametry $\delta_1, \delta_2, \delta_3, \delta_4, \delta_5$ jest poprawne, jednak z punktu widzenia procesu optymalizacji, kryterium to nie jest właściwie sformułowane. Jest to spowodowane niezachowaniem preferowanej proporcji przez decydenta pomiędzy kryteriami cząstkowymi, które powinny zapewnić parametry $\delta_1, \delta_2, \delta_3, \delta_4, \delta_5$. Sytuację tą można zilustrować przykładem: dla decydenta wszystkie pięć kryteriów ma taką samą wagę: $\delta_1 = 1$ [zł/h], $\delta_2 = 1$ [zł/km], $\delta_3 = 1$ [zł/h], $\delta_4 = 1$ [zł/h] oraz $\delta_5 = 1$ [zł/pojazd]. W procesie optymalizacji cząstkowe funkcje kryterialne przyjęły następujące wartości: $f_1 = 1$ [h], $f_2 = 10$ [km], $f_3 = 0$ [h], $f_4 = 0,25$ [h] oraz $f_5 = 2$ [pojazd]. Wartość funkcji kryterialnej wyniesie: $f = 1 + 10 + 0 + 0,25 + 2 = 13,25$ [zł]. Jak można zauważyć, preferencja decydenta o równości wszystkich kryteriów cząstkowych nie została zachowana, ponieważ udział wartości dystansu w globalnej funkcji celu okazał się 10 razy ważniejszy niż udział wartości kryterium czasu. W takiej formule funkcji kryterialnej, algorytm optymalizacyjny będzie przeszukiwał przestrzeń rozwiązań dopuszczalnych w kierunku kryterium cząstkowemu do-

minującym. Przytaczając powyższy przykład, w drodze optymalizacji możliwe jest uzyskanie trasy, która jest tylko najkrótsza.

4.1.4 NORMALIZACJA FUNKCJI KRYTERIALNEJ PROBLEMU TD-VRP-STW

W celu wprowadzenia właściwych preferencji decydenta do modelu, można wykonać normalizację każdego z kryteriów cząstkowych. Normalizacja kryteriów cząstkowych spowoduje, że każde z kryteriów cząstkowych będzie porównywalne względem siebie. Do normalizacji wykorzystano tzw. metodę normalizacji min-max, która przeprowadza transformację liniową danych wejściowych do zakresu $[0,1]$. Nowy zapis modelu ($VRP1^T$) przyjmie, zatem postać następującą:

$$(nVRP1^T): \min_{F_i} \sum_{i=1}^4 \omega 1_i F_i \quad (4.23)$$

przy ograniczeniach: (4.2) - (4.18).

Zmienna F_i jest znormalizowaną wartością kryterium cząstkowego wyznaczonego przez normalizację typu min-max, czyli:

$$F_i: F_i = \frac{f_i - Fa_i}{Fb_i - Fa_i}, F_i \in \mathbb{R}^+, i = 1, \dots, 4 \quad (4.24)$$

gdzie:

Fa_1, Fa_2, Fa_3, Fa_4 - oznacza wartość minimalną, jaką może przyjąć funkcja danego kryterium cząstkowego, odpowiednio dla: czasu, odległości, czasu oczekiwania oraz czasu opóźnienia,

Fb_1, Fb_2, Fb_3, Fb_4 - oznacza wartość maksymalną, jaką może przyjąć funkcja danego kryterium cząstkowego, odpowiednio dla: czasu, odległości, czasu oczekiwania oraz czasu opóźnienia.

Zakłada się, że minimalne i maksymalne wartości poszczególnych funkcji przynależą do zbioru: $F_{N1} = \{(Fa_i, Fb_i): Fa_i, Fb_i \in \mathbb{R}^+, i = 1, \dots, 4\}$.

Dodatkowo w zależności (4.23) parametry jednostkowych kosztów $\delta_1, \delta_2, \delta_3, \delta_4$ zostały zamienione na wagi $\omega 1_1, \omega 1_2, \omega 1_3, \omega 1_4$, oznaczające ważność danego kryterium. Zgodnie z teorią optymalizacji pożądanym jest, aby funkcja celu dowolnego problemu optymalizacyjnego była sformułowana w postaci funkcji wypukłej. Cechą funkcji wypukłej jest posiadanie tylko globalnych minimów, przeciwnie niż w funkcjach niewypukłych, gdzie możliwe jest występowanie również wielu minimów lokalnych [56]. W celu stworzenia kombinacji wypukłej powyższej funkcji, wartości wag powinny spełniać warunek:

$$\sum_{i=1}^4 \omega 1_i = 1 \wedge \forall \omega 1_i \geq 0 \quad (4.25)$$

Poszczególne wagi wraz z powyższym założeniem można sformułować w postaci zbioru: $\Omega_1 = \{\omega 1_i: \sum_{i=1}^4 \omega 1_i = 1 \wedge \forall \omega 1_i \geq 0, i = 1, \dots, 4\}$.

Analogicznie została zapisana druga wersja problemu TD-VRP-STW, gdzie zakłada się, że liczba pojazdów jest zmienna i przyjmuje wartości z zakresu $[1, K]$. Funkcja kryterialna przyjmie postać:

$$(nVRP2^T): \min_{F_i} \sum_{i=1}^5 \omega 2_i F_i \quad (4.26)$$

przy ograniczeniach: (4.2) - (4.5); (4.7); (4.9) - (4.16) oraz (4.20) - (4.22).

Zmienna F_i jest znormalizowaną wartością kryterium cząstkowego wyznaczonego przez normalizację typu min-max, czyli:

$$F_i = \frac{f_i - Fa_i}{Fb_i - Fa_i}, F_i \in \mathbb{R}^+, i = 1, \dots, 5 \quad (4.27)$$

Gdzie interpretacja dla $\{Fa_i, Fb_i\} \in F_{N1}$ jest taka sama jak w modelu $(nVRP1^T)$, a $\{Fa_5, Fb_5\}$ oznacza minimalną/maksymalną liczbę pojazdów jaka może być użyta do obsługi danego popytu i podaży. Wartości parametrów normalizujących kryteria cząstkowe zawierają się w zbiorze: $F_{N2} = \{(Fa_i, Fb_i): Fa_i, Fb_i \in \mathbb{R}^+, i = 1, \dots, 5\}$. Wagi funkcji kryterialnej powinny spełniać warunek:

$$\sum_{i=1}^5 \omega 2_i = 1 \wedge \forall \omega 2_i \geq 0 \quad (4.28)$$

A ich wartości zawierają się w zbiorze: $\Omega_2 = \{\omega 2_i: \sum_{i=1}^5 \omega 2_i = 1 \wedge \forall \omega 2_i \geq 0, i = 1, \dots, 5\}$.

4.1.5 CHARAKTERYSTYKA ORAZ UŻYTECZNOŚĆ MODELI DLA PROBLEMU TD-VRP-STW

Zaprezentowane obie wersje problemu TD-VRP-STW zostały sformułowane w celu formalnego opisu problemu, jednak próba rozwiązania ich w przedstawionej postaci charakteryzuje się niskim poziomem użyteczności w rzeczywistym procesie decyzyjnym. Jest to spowodowane dwoma faktami:

1. Model należy do rodziny problemów VRP, które posiadają poziom złożoności NP-trudny,
2. Ograniczenia (4.7), (4.8) oraz (4.17) wymuszają, że pojazd może przejechać przez dany łuk w grafie tylko raz.

Z uwagi na kombinatoryczny charakter przedstawionego zadania, możliwość rozwiązywania problemów klasy VRP przez algorytmy i metody dokładne jest dość ograniczona. Dla przykładu, rozważane modele posiadają użyteczność stosowania do 15 klientów. Powyżej tej granicy czas obliczeń rośnie wykładniczo (po 3 godzinach obliczeń, dla 16 klientów algorytm nie odnalazł rozwiązania optymalnego). Dotychczasowa liczba klientów w sieci, jaka jest rozwiązywana przez metody dokładne, tj. relaksacja Lagrange'a, metoda podział kolumn (dekompozycja Benders'a), czy też programowanie dynamiczne, to 100 do 150, jednakże czas obliczeń nie jest wystarczająco krótki, aby zastosowanie tych metod w rzeczywistości było racjonalne [53, 114, 145]. Niektóre z metod dokładnych dają w rezultacie rozwiązanie optymalne, lecz czas obliczeń wynosi od kilku sekund do nawet kilkunastu godzin, w zależności od testowanego przypadku [53]. Z uwagi na przytoczone fakty, wielu naukowców na świecie stosuje metody przybliżone do rozwiązywania problemów klasy VRP. Do metod przybliżo-

nych można zaliczyć: metody heurystyczne (iteracyjne), metody oparte na sztucznej inteligencji oraz metody zmniejszające złożoność problemu oryginalnego [11]. Do metod zmniejszających złożoność problemu VRP można zaliczyć m.in. analizę skupień (ang. Clustering), która została omówiono bardziej szczegółowo w dalszej części rozdziału.

Druga wspomniana kwestia, która powoduje, że zaproponowany formalny zapis modeli: $(nVRP1^T)$ oraz $(nVRP2^T)$ nie nadaje się do bezpośredniej implementacji w rzeczywistości, to występowanie ograniczeń definiujących poprawność przejazdu pojazdów. Ograniczenia (4.6), (4.7) oraz warunek binarności zmiennej objaśniającej zakładają, że jeśli jeden pojazd obsłuży danego klienta (wierzchołek), to staje się on już niedostępny dla pozostałych pojazdów (pojazd nie może przejechać przez dany odcinek/wierzchołek więcej niż raz). Wraz z wierzchołkami niedostępne stają się też przyległe krawędzie i łuki grafu. Wprowadzenie takiej formy ograniczeń wynika z logicznej poprawności modelu matematycznego - każdy klient musi być przypisany tylko do jednego pojazdu. Ze względu na swoją prostotę, zapis ten w mniej lub bardziej zmodyfikowanej formie jest powszechnie funkcjonującym w literaturze przedmiotu [145]. Jednak w rzeczywistej dystrybucji towarów warunek ten nie ma żadnego uzasadnienia, ponieważ pojazdy mogą dowolnie przemieszczać się w sieci drogowej i pokonywać dany odcinek drogowy tylurotnie ile wymaga tego proces rozwożenia towarów.

Dodatkowo zgodnie z założeniami zaprezentowanego modelu każdy wierzchołek w grafie musi mieć przypisany popyt i może mieć przypisaną podaż na towary. W rzeczywistej sieci drogowej lokalizacja klientów, którzy wymagają obsługi transportowej, występuje losowo, czyli ujmując to w reprezentacji grafowej - niektóre wierzchołki mogą mieć przypisany popyt lub podaż, a niektóre nie. Wobec czego, z logicznego punktu widzenia, pojazd realizujący transport nie musi przejechać przez wszystkie istniejące wierzchołki grafu. Jednak ograniczenie (4.7) (lub (4.21) w drugiej wersji zapisu) wymusza, że wszystkie wierzchołki grafu muszą znaleźć się w rozwiązaniu (muszą być przypisane do którejś trasy), czyli pojazd miałby przejeżdżać przez dane wierzchołki, pomimo że nie miałoby to żadnego ekonomicznego uzasadnienia. Rozwiązanie takiego stanu rzeczy jest możliwe przez: modyfikację zapisu matematycznego lub przeprowadzenie procesu upraszczającego rzeczywistą sieć drogową.

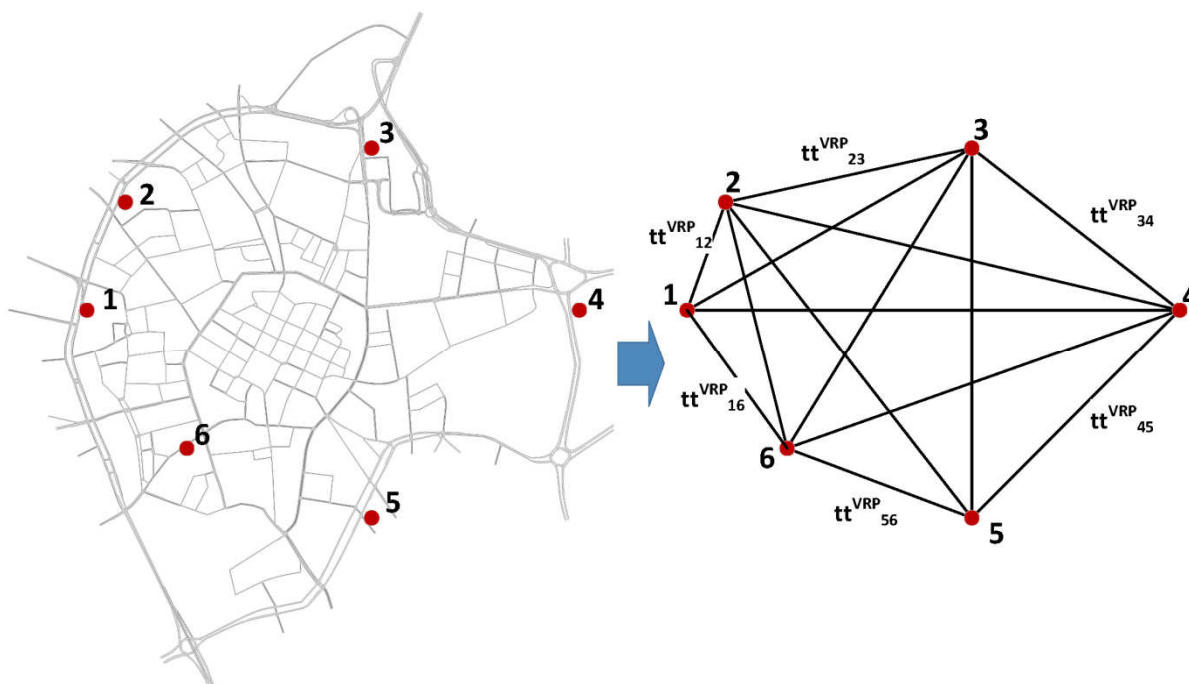
W pierwszym podejściu model jest definiowany, jako problem uogólniający klasyczne modele VRP - model wyznaczania tras pojazdom z klientami w wierzchołkach oraz łukach sieci (ang. Node, Edge and Arc Routing Problem) [15, 111]. W założeniach takich modeli zakłada się istnienie wierzchołków w grafie, które nie są klientami (wierzchołki potencjalnie przejezdne) oraz te, które są klientami. Dodatkowo możliwe jest wykorzystywanie wielokrotne danego łuku grafu w rozwiązaniu. Jednakże zmodyfikowany zapis matematyczny jest na tyle złożony, że możliwe metody rozwiązywania tego typu problemów to tylko metaheurystyki i połączenia hybrydowe różnych technik heurystycznych. Mając na uwadze, fakt iż celem pracy jest sformułowanie odpornej wersji problemu TD-VRP-STW, zmiana zapisu ograniczeń na bardziej zaawansowane (uwzględniające możliwość wielokrotnego przejazdu pojazdu oraz niepewność czasów przejazdu) nie będzie właściwym kierunkiem, ponieważ poziom skomplikowania wzrośnie na tyle, że nie będzie można wskazać adekwatnej metody optymalizacyjnej.

Proces uproszczenia sieci polega na zastąpieniu sieci oryginalnej (np. rzeczywistej) przez sieć sztuczną, utworzoną przez obliczenie najkrótszych ścieżek pomiędzy analizowanymi punktami [48, 145]. Własnością każdej rzeczywistej sieci drogowej miasta jest fakt, że

z każdego miejsca w sieci można dojechać do pozostałych miejsc. Cechę tą można wykorzystać do obliczenia parami wszystkich możliwych kombinacji połączeń pomiędzy klientami, przez co uzyska się pełną macierz czasów przejazdów. Metoda ta składa się z dwóch etapów:

1. Obliczenie najkrótszych ścieżek w sieci rzeczywistej pomiędzy wszystkimi kombinacjami klientów,
2. Wykonanie optymalizacji modelu VRP wykorzystującego zredukowany graf z etapu pierwszego,
3. Połączenie sekwencji odwiedzania klientów z najkrótszymi ścieżkami, w celu wyznaczenia trasy przejazdu pojazdów.

Omawianą metodę redukcji problemu przedstawia rysunek 4.3. W nowym grafie krawędzie reprezentują bezpośrednie połączenie pomiędzy poszczególnymi wierzchołkami (klientami), a wagi przypisane do krawędzi oznaczają czas przejazdu od jednego punktu do drugiego. Macierz połączeń i kosztów niekoniecznie musi być symetryczna. Takie uproszczenie rzeczywistej sieci umożliwia stosowanie modeli matematycznych VRP, które posiadają ograniczenia w wyżej przedstawionej postaci.



Rysunek 4.3. Rzeczywista sieć drogowa z zaznaczonymi klientami (z lewej) oraz jej reprezentacja w postaci grafu pełnego (z prawej).

Źródło: opracowanie własne.

Zaprezentowane podejście upraszczania sieci drogowej wraz z modelami ($nVRP1^T$) i ($nVRP2^T$) posłużą do dalszych rozważań nad możliwością ujęcia niepewności danych z uwzględnieniem specyfiki ruchu miejskiego.

4.2 METODYKA ROZWIĄZYWANIA ZAGADNIENÍ WYZNACZANIA TRAS POJAZDÓW Z PARAMETRAMI NIEPEWNYMI

Celem pracy jest zdefiniowanie problemu wyznaczania tras pojazdów, w którym uwzględniono elastyczne okna czasowe obsługi, wsteczne przepływy towarów oraz niepewność danych, które są zależne od czasu (ang. Robust Time-Dependent Pickup and Delivery Vehicle Routing Problem with Soft Time Windows - dalej R-TD-VRP-STW). W zaproponowanych nominalnych modelach ($nVRP1^T$) lub ($nVRP2^T$) brakuje jeszcze założenia o niepewności wartości parametrów - czasie przejazdu. Dodatkowo w oparciu o przytoczoną metodę optymalizacji odpornej rozważono wprowadzenie niepewności w czasie obsługi klienta. Implementacja założeń optymalizacji odpornej bezpośrednio do modeli ($nVRP1^T$) lub ($nVRP2^T$), nie jest właściwym podejściem, ponieważ nie opisuje ono poprawnie: zmienności czasu przejazdu w czasie w sieci drogowej oraz procesu przemieszczania się pojazdu w sieci drogowej miasta.

4.2.1 NIEPEWNOŚĆ WARTOŚCI CZASU OBSŁUGI W PROBLEMIE TD-VRP-STW

Czas obsługi klienta jest rozumiany, jako różnica pomiędzy czasem odjazdu kierowcy od klienta, a czasem przyjazdu kierowcy do klienta. Składają się na to takie operacje jak czas przygotowania przesyłki, czas ewentualnego dojścia kierowcy do klienta, przekazanie paczki, powrót kierowcy do pojazdu oraz czas załadowania odebranej paczki na pojazd, jeśli występuje. Zatem, czas obsługi klienta zależy od wielu losowych czynników. Odnosząc się do modelu ($nVRP^T$) czas obsługi st_i jest określony w ograniczeniach (4.12) oraz (4.13). W ograniczeniach tych czas obsługi jest wyrazem wolnym, czyli po przeformułowaniu do postaci standartowej programowania liniowego, będzie on prawą stroną ograniczenia. Jak to wspomniano wcześniej (podrozdział 3.3), jeśli prawa strona ograniczenia jest poddana losowym perturbacjom, można ją sformułować w postaci dodatkowej zmiennej x_{n+1} , która przyjmie wartości z przedziału $-1 \leq x_{n+1} \leq 1$. Dodatkowo mając na uwadze, że zbiór niepewności czasu obsługi jest niezależny od zbioru niepewności czasu przejazdu, konieczne będzie zdefiniowanie osobnych zbiorów niepewności i korespondujących z nimi zbiorów perturbacji. Oznacza to, że w postaci standartowej w każdym ograniczeniu (4.12) lub (4.13) zmienność czasu obsługi będzie opisana jedną zmienną losową ξ_i . Czas obsługi poszczególnych klientów jest od siebie niezależny, a więc należałoby przyjąć dla każdego ograniczenia osobny parametr konserwatywności Γ_i (na podstawie modelu (RC2)). Dalej przyjmując, że sposób poszukiwania odpornego rozwiązania w przestrzeni rozwiązań zdefiniowany w (3.6) jest kresem górnym zbioru, to wartość czasu obsługi zamodelowanej przedziałem afinicznym, zawsze przyjmie wartość maksymalną.

Innymi słowy, wprowadzenie niepewności czasu obsługi zgodnie z założeniami klasycznej optymalizacji odpornej przedstawionej w pracy, będzie się sprowadzać do uzyskiwania rozwiązania, w którym przyjęto maksymalny czas obsługi klienta. Sprowadza się to do wniosku, że nie ma potrzeby modelować niepewności czasu obsługi, ponieważ wystarczy założyć maksymalny, potencjalny czas obsługi i wykorzystać sformułowania deterministyczne. Oczywiście jest, że może istnieć różnica pomiędzy rozwiązaniem gdzie przyjęto np. średni czas obsługi, a rozwiązaniem gdzie przyjęto maksymalny czas obsługi. Różnica jest dość przewidywalna, wobec czego niepewność czasu obsługi w dalszych rozważaniach zostanie

pominięta. Uwzględnianie jej sprowadzałoby się do przyjmowania przewidywanej wartości maksymalnej, czyli badania wpływu zmiany wartości deterministycznej na rozwiązanie.

4.2.2 NIEPEWNOŚĆ WARTOŚCI CZASU PRZEJAZDU PRZEZ ODCINKI DROGOWE W PROBLEMIE TD-VRP-STW

W rzeczywistych sieciach drogowych miasta taka cecha macierzy połączeń zdefiniowanej zbiorem skierowanych łuków **AP** nie występuje. Warunek ten jest realizowany przez obliczenie dla wszystkich par klientów najkrótszych ścieżek. Reprezentacja grafowa rzeczywistej sieci drogowej ma taką cechę, że z każdego miejsca można dojechać do każdego miejsca w sieci drogowej. Stąd możliwe jest utworzenie pełnej macierzy kosztów wymaganej przez założenia modelu VRP.

Jednakże przyjęcie warunków o pełności grafu oraz sposobie poruszania się pojazdów w sieci jest właściwe tylko w przypadku analizy problemu deterministycznego. W sytuacji, gdy dane są danymi niepewnymi, istotne jest wskazanie, na którym etapie modelowania należy wprowadzić niepewność parametrów modelu: czy bezpośrednio do modelu VRP, czy w etapie obliczania najkrótszych ścieżek. Jak przedstawiono to w rozdziale poprzednim, popularnym w literaturze podejściem przy modelowaniu niepewności zjawisk jest wprowadzanie danych niepewnych bezpośrednio do modeli VRP. Jednak takie podejście nie do końca odpowiada poprawnemu opisowi rzeczywistego obiektu. Wadę takiego podejścia można przedstawić na przykładzie zaprezentowanym na rysunku 4.3: wirtualne połączenie pomiędzy wierzchołkami (2,3) posiada przypisaną swoją wagę, która oznacza np. czas przejazdu oraz jest ono złożone z ciągu kolejnych odcinków sieci, tworzących najkrótszą ścieżkę. W przypadku wykorzystywania modelu odpornego VRP, należałoby podać, jaki jest stopień niepewności takiego połączenia. Czyli zgodnie z koncepcją afiniczności niepewności należałoby podać, jaki byłby minimalny i maksymalny czas przejazdu pomiędzy parą (2,3). Jednak taka reprezentacja danych powodowałaby, że wszystkim odcinkom w najkrótszej ścieżce pary (2,3), przypisano by taki sam zakres zmienności i taki sam poziom niepewności czasu przejazdu. W rzeczywistości każdy odcinek sieci drogowej miasta posiada swój własny poziom niepewności, pomimo, że dany zbiór kolejnych odcinków może leżeć wzdłuż jednej arterii. Występowanie propagacji czasu przejazdu na kolejnych odcinkach nie gwarantuje takiego samego sposobu zmienności w czasie przejazdu na tych odcinkach drogowych. Jest to naturalna cecha rzeczywistej sieci drogowej w miastach, która może być wynikiem: lokalizacji danego odcinka, układu komunikacyjnego miasta, rozkładu strumieni pojazdów, charakterystyki układu przyległych skrzyżowań, sposobu działania sygnalizacji świetlnej, itp. Jak wskazano to w przeglądzie literatury, obecnie większość prac, w których rozważa się odporne modele VRP pomija tą kwestię.

Druga wada takiego podejścia to kwestia interpretacji najkrótszej ścieżki oraz przypisanych do niej zmiennych kosztów przejazdu, które zdefiniują zbiór niepewności wartości danych. Cechę tą może wyjaśnić eksperyment myślowym wraz z odnoszeniem się do przytaczanego wcześniej rysunek 4.3. Załóżmy, że rozważana jest para wierzchołków {6,3}. W zależności od parametrów ruchowych, parę tę można połączyć zbiorem różnych, najkrótszych ścieżek. Zbiór tych ścieżek można opisać w postaci zakresu zmienności przyjętego kosztu, co może posłużyć do zdefiniowania zbioru niepewności dla modelu VRP. Zbiór niepewności został opisany przez wartości kosztów, które odnoszą się do zbioru ścieżek. Przy zmiennych

i losowych warunkach ruchowych, zakresy zmienności kosztu dla poszczególnych ścieżek mogą mieć część wspólną. Jeśli więc w trakcie optymalizacji odpornej na wahania zostanie wyznaczona trasa pojazdu gdzie występuje połączenie $\{6,3\}$, to powstaje pytanie - która ścieżka z tego zbioru będzie odnosić się do otrzymanego połączenia? Oczywiście istnieje możliwość uniknięcia tego pytania, przez zastosowanie wielokrotnych, równoległych połączeń w grafie, lecz taka reprezentacja połączeń pomiędzy klientami wymuszałaby zdefiniowanie dodatkowego wymiaru zmiennych modelu VRP, co bezpośrednio i istotnie wpływa na poziom dostępności algorytmicznej. Odnosząc się do przeglądu literatury z podrozdziału 3.4, w żadnej z przytoczonych prac nie wykorzystano takiego założenia. Prawdopodobnie wynika to z dużego nakładu pracy potrzebnego do wyznaczenia wszystkich możliwych ścieżek pomiędzy wszystkimi parami w zależności od różnych warunków ruchowych oraz zwiększonej złożoności modelu VRP. Stąd implementacja założenia o niepewności parametrów modelu bezpośrednio do modelu wyznaczania tras jest sporym uproszczeniem rzeczywistości.

Trzecim elementem, który istotnie podważa zasadność stosowania koncepcji odpornych odpowiedników wprost w modelu VRP jest logiczna struktura ograniczeń. Zakładając, że niepewność parametrów modelu dotyczy tylko czasu przejazdu, ograniczeniami, które mogą być poddane losowym perturbacjom są zależności od (4.13) do (4.16). Przekładając je do postaci standardowej programowania liniowego, powstaną wiersze macierzy ograniczeń \tilde{A} z tylko jednym elementem poddanym losowym perturbacjom w wybranych wierszach. Nawiązując teraz do koncepcji "niepewności w ramach budżetu" przedstawionej modelem (RC_{MIP}) i założenia o afiniczności danych niepewnych, sprowadzi się to do optymalizacji min-max, czyli uzyskania rozwiązania z wysokim poziomem konserwatywności.

Możliwość uniknięcia powyższych efektów daje podejście zaprezentowane w pracach [48, 49, 129] oraz w artykułach autora dysertacji [81]. W pracach tych uproszczenie sieci rzeczywistej odbywa się przez tzw. integrację problematyki odpornego wyznaczania ścieżek z problemem wyznaczania tras pojazdów. Koncepcja ta jest oparta o klasyczne podejście generowania bezpośrednich połączeń pomiędzy dowolnymi punktami w sieci (tu klienci) na podstawie problemu najkrótszej ścieżki. Główną ideą takiego podejścia jest przeniesienie cechy "uodparniania rozwiązania" z problemu VRP na problem najkrótszej ścieżki. Dopiero po wyznaczeniu odpornych ścieżek wyznacza się trasy pojazdów zgodnie z klasycznymi modelami VRP. Niektóre pozycje literatury przedmiotu definiują ten proces jako wstępne przetwarzanie danych (ang. data preprocessing) [145]. Rezultatem takich działań jest dekompozycja oryginalnego problemu R-TD-VRP-STW na dwa zagadnienia: problem odpornych najkrótszych ścieżek R-SPP oraz problem wyznaczania tras pojazdów uwzględniający elastyczne okna czasowe obsługi oraz rewersyjne przepływy towarów (ang. Pickup and Delivery Vehicle Routing Problem with Soft Time Windows - dalej VRP-STW).

Idea połączenia dwóch modeli: najkrótszych ścieżek i modeli wyznaczania tras pojazdów posiada następujące cechy:

1. Możliwość aplikacji tylko do zagadnień wyznaczania tras pojazdów, w których występują okna czasowe obsługi u klientów,
2. Lepiej odzwierciedla rzeczywisty obiekt, jakim jest system dystrybucji towarów w mieście,

3. Zmniejsza poziom złożoności modeli matematycznych problemów klasy VRP, szczególnie modeli w wersji odpornej na wahania,
4. Wprowadzenie niepewności danych modelu jest uwzględniane na etapie obliczania najkrótszych ścieżek pomiędzy parami klientów,
5. Możliwe jest wskazanie metod optymalizacyjnych, które dostarczą rozwiązanie dobrej jakości, w rozsądnym czasie obliczeń,
6. Obliczenia w procesie wstępnego przetwarzania danych można rozproszyć na kilka stacji roboczych (równoległe obliczenia),
7. W praktyce etap modelowania niepewności odbywałby się przed procesem układania tras przez dyspozytora,
8. Możliwość uproszczania modeli zależnych od czasu do deterministycznych wersji,
9. W przypadku modeli zależnych od czasu, dokładność metody zależy od stosunki długości okna czasowego obsługi i częstotliwości próbkowania pomiarów ruchu.

Proponowane podejście charakteryzuje się elastycznością aplikacji w różnych wariantach problemów klasy VRP z oknami czasowymi (tabela 4-1). W najprostszej formie (dane deterministyczne niezależne od czasu) można uzyskać klasyczny wariant wyznaczania tras pojazdów w rzeczywistych sieciach. Uzasadnieniem stosowania jest w takim przypadku możliwość zredukowania przestrzeni obszaru poszukiwań rozwiązania. Dla przypadków: $e_{org} \geq l_{des}$, koszt połączenia wierzchołków $\{org, des\}$ będzie nieskończenie duży. Jest to redukcja problemu wynikająca z ułożenia okien czasowych obsługi na osi czasu. Analogiczny efekt redukcji uzyskuje się w wariacie odpornym niezależnym od czasu. Zasadnicza zaleta takiego podejścia wprowadzona odporność w model SPP, implikuje odporność modelu VRP z oknami czasowymi.

W przypadku modeli deterministycznych zależnych od czasu tj. model ($nVRP^T$), oprócz redukcji wynikającej z okien czasowych, można dodatkowo uzyskać redukcję zależności modelu VRP od czasu do postaci jednego interwału czasowego, gdzie: $|T| = 1$. Dodatkowe założenie o zmienności czasu przejazdu w czasie wpływa na poziom złożoności obliczeniowej modelu VRP. Założenie to można przenieść na problem najkrótszej ścieżki, wykorzystując charakterystykę dystrybucji towarów w miastach. W ten sposób można uzyskać aproksymację problemu VRP, którego wartości danych zależą od czasu. Własnością miejskiego podsystemu transportu towarów jest wysoka koncentracja popytu na niewielkim obszarze. Determinuje to względnie nieduży czas poruszania się z punktu "A" do punktu "B" miasta. Dodatkowo, biorąc pod uwagę istnienie okien czasowych u klientów, można założyć, że przy wyznaczaniu najkrótszych połączeń będą brane pod uwagę czasy przejazdu w sieci drogowej zależne od przypisanego okna czasowego obsługi. Innymi słowy, jeśli pojazd będzie wyruszał z punktu "A" w chwili "t", to ścieżka wyznaczana do kolejnego punktu "B", będzie wytyczona w oparciu o aktualne czasy przejazdu w sieci w chwili "t". Mając wiedzę, że chwila "t" musi znajdować się w oknie czasowym klienta, można wskazać, które dane o czasach przejazdu będą wybrane do obliczenia najkrótszych ścieżek przed rozpoczęciem procesu optymalizacji tras pojazdów. Założenie to można również zilustrować, jako sytuację, kiedy to kierowca pojazdu logistyki miejskiej, w trakcie realizacji trasy, decyduje o tym którą ma jechać. Decyzja ta jest podejmowana w oparciu o porę dnia, w której się znajduje, jego doświadczenie oraz intuicję możliwych warunków ruchowych w danej chwili w mieście. Jak wynika to z przeprowa-

dzonego wywiadu z firmą transportową, wybór trasy w stu procentach zależy od doświadczenia i intuicji kierowcy, a więc założenie to jest dość bliskie rzeczywistym warunkom.

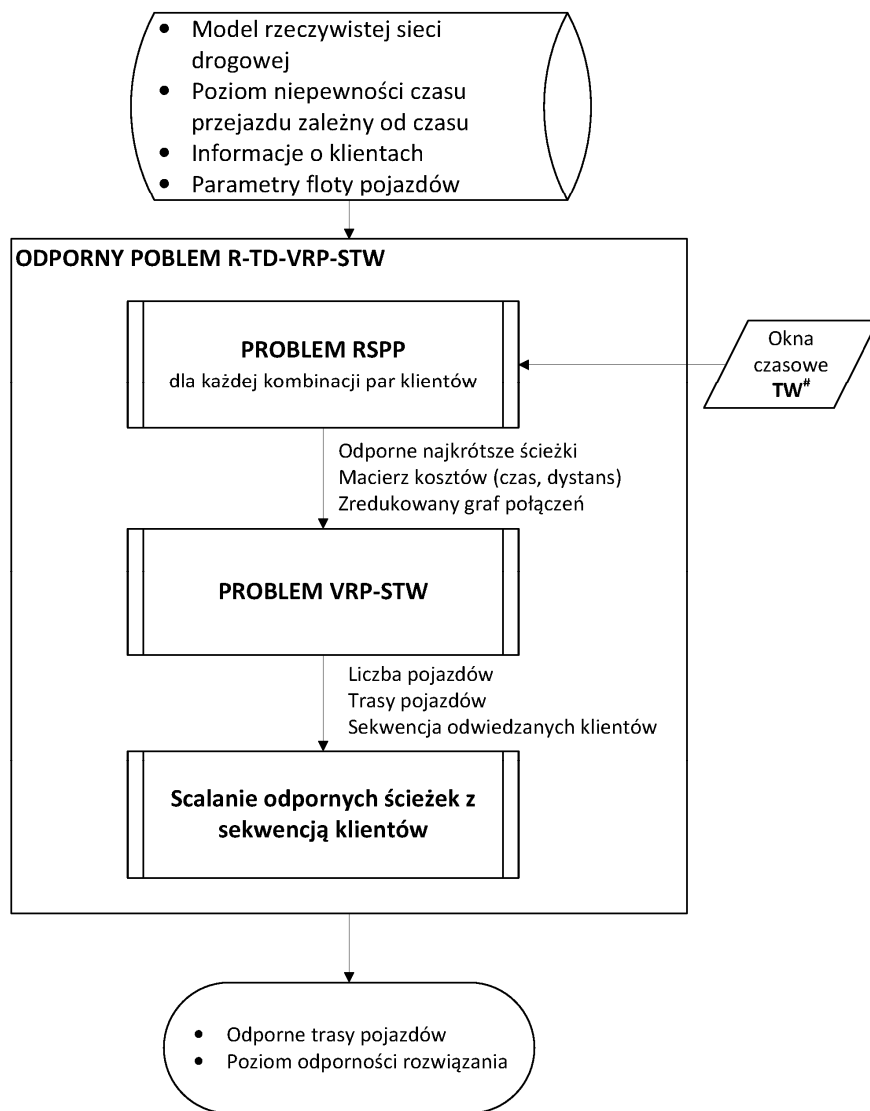
Tabela 4-1. Warianty integracji problemów SPP z problemami VRP.

	Wariant deterministyczny	Wariant odporny
Dane stałe w czasie	Problem najkrótszej ścieżki + Problem wyznaczania tras = Problem wyznaczania tras na rzeczywistych sieciach	Odporny problem najkrótszej ścieżki + Problem wyznaczania tras = Odporny problem wyznaczania tras na rzeczywistych sieciach
Dane zależne od czasu	Problem najkrótszej ścieżki zależny od czasu + Problem wyznaczania tras = Problem wyznaczania tras na rzeczywistych sieciach zależny od czasu	Odporny problem najkrótszej ścieżki zależny od czasu + Problem wyznaczania tras = Odporny problem wyznaczania tras na rzeczywistych sieciach zależny od czasu

Źródło: opracowanie własne.

Błąd uzyskanego rozwiązania przez zastosowanie dekompozycji problemów zależnych od czasu, zależy od punktu porównawczego. Jeśli porównanie zostanie wykonane w stosunku do rzeczywistego procesu transportowego, czyli intuicji kierowcy, błąd powinien być nieduży lub wręcz zerowy (kwestią fundamentalną tutaj jest określenie jak kierowca wyznacza ścieżkę). Z kolei, jeśli punktem porównawczym będzie model VRP zależny od czasu, to wartość błędu przybliżenia będzie uzależniona w głównej mierze od stosunku szerokości interwału czasowego $|tw_i|$ u i-tego klienta z krokiem zmienności danych $|ti_i|$. Jeśli $\frac{|tw_i|}{|ti_i|} \leq 1, \forall i \in VP$, to podejście integracji jest dokładnym odzwierciedleniem oryginalnego problemu. Z kolei, jeśli $\frac{|tw_i|}{|ti_i|} > 1, \forall i \in VP$, oznacza to, że podejście jest przybliżeniem problemu wyznaczania tras zależnego od czasu. Im większy jest stosunek tych wartości, tym uzyskane rozwiązanie jest potencjalnie narażone na większy błąd przybliżenia.

Ostatni zaprezentowany wariant proponowanej metody z tabeli 4-1 jest uogólnieniem poprzednich - jest to dekompozycja odpornego problemu wyznaczania tras pojazdom, w którym dane zależą od czasu. Na rysunku 4.4 przedstawiono schemat rozważanej idei. Schemat ten można upraszczać do wariantów przedstawionych w tabeli 4-1.



Rysunek 4.4. Koncepcja integracji problemu R-SPP odpornego na wahania parametrów z problemami klasy VRP.

Źródło: opracowanie własne na podstawie [81].

Na podstawie otrzymanych danych o klientach, uwzględniając charakterystykę rozważanego obszaru oraz poziom niepewności czasu przejazdu są wyznaczane odporne, najkrótsze ścieżki dla wszystkich par zbioru klientów i magazynu. W procesie tym uzyskuje się również informacje na temat związanych z nimi kosztami - czas przejazdu oraz dystans ścieżek. W wyniku tego etapu następuje redukcja odpornego problemu zależnego od czasu do wersji deterministycznej nie zależnej od czasu. Na bazie otrzymanych informacji są wyznaczane trasy pojazdów. Łącząc sekwencje odwiedzanych klientów dla każdej trasy z odpornymi ścieżkami uzyskiwane są odporne trasy wytyczone w rzeczywistej sieci drogowej.

Szczegółowy przepływ informacji w zaprezentowanym podejściu został zademonstrowany pod koniec tego rozdziału. Kolejnym etapem jest prezentacja kluczowego elementu proponowanego podejścia modelowania niepewności w zagadnieniach wyznaczania tras, czyli odpornego problemu najkrótszej ścieżki.

4.3 DWUKRYTERIALNY PROBLEM OPTYMALIZACYJNY NAJKRÓTSZEJ ŚCIEŻKI

Problem najkrótszej ścieżki (ang. Shortest Path Problem - dalej SPP) jest bardzo dobrze znanym i popularnym zagadnieniem z dziedziny badań operacyjnych. Celem problemu jest odnalezienie ścieżki pomiędzy dwoma dowolnymi punktami w sieci drogowej, przy uwzględnieniu danego kryterium, najczęściej najmniejszej odległości.

W literaturze przedmiotu można odnaleźć dwa wiodące podejścia do formułowania modeli SPP z niepewnymi parametrami i rozwiązywania ich przy pomocy podejść typu "robust". Pierwsze jest oparte o poszukiwanie ścieżki o tzw. najmniejszym żalu (ang. Relative Robust Shortest Path) [112]. Drugie wykorzystuje teorię optymalizacji odpornej, gdzie poszukuje się ścieżki o najmniejszej możliwej do wystąpienia różnicy pomiędzy odchyłką, a wartością oczekiwaną. Pierwsze podejście do problemów SPP odpornych na wahania parametrów są oparte na minimalizacji "żalu", gdzie zakłada się, że "żalem decyzji" jest największe możliwe odchylenie kosztu od rozwiązania optymalnego. Celem takiego modelu jest minimalizacja takiego odchylenia w każdym możliwym scenariuszu [101, 102, 112]. Jednakże jak pokazują dotychczasowe prace [76, 102, 112], podejście to charakteryzuje się dość dużym zapotrzebowaniem na moce obliczeniowe komputera. Dla przykładu obliczenie odpornej ścieżki dla sieci złożonej z 240 wierzchołków i 480 łuków zajęło 76,96 sekund [76]. Dodatkowo należy tu zaznaczyć, że optymalizacja była wykonana w oparciu o jedno kryterium. Dla porównania - reprezentacja graficzna sieci drogowej z rysunku 4.3 (centrum miasta Krakowa) składa się z 251 wierzchołków oraz 564 łuków i jak pokazują symulacje w dalszej części pracy wykorzystujące optymalizację odporną na wahania parametrów, czas obliczeń średnio wynosi 0,18 sekundy. Wobec powyższego użyteczność podejścia "najmniejszego żalu" jest dość niska. Konkludując, dalsze rozważania na temat odpornego modelu SPP będą oparte o teorię optymalizacji odpornościowej, która wykazuje się zdecydowanie lepszym czasem optymalizacji [28, 80, 82, 83].

4.3.1 WERSJA DETERMINISTYCZNA PROBLEMU NAJKRÓTSZEJ ŚCIEŻKI - SPP

Mając na względzie kryteria modelu ($nVRP^T$), przyjęto, że deterministyczny problem SPP będzie uwzględniał dwa kryteria - minimalizację czasu przejazdu oraz pokonanego dystansu. Dodatkowo, z uwagi na zależność oryginalnego modelu od czasu, przyjęto, że problem SPP będzie miał możliwość wyboru kosztów w zależności od wartości czasu. Formuła poszukiwania pozostanie taka sama - celem będzie odnalezienie najkrótszej ścieżki, której znormalizowana wartość funkcji celu będzie najmniejsza.

Matematyczny model SPP został utworzony w oparciu o dotychczasowe badania zaprezentowane w pracach [80] i został on sformułowany w postaci problemu mieszanego całkowitoliczbowego. W modelu zagadnienia SPP wykorzystano reprezentację grafową sieci drogowej, czyli definiowany już graf skierowany: $GS = \langle VS, AS \rangle$.

Problem sprowadza się do znalezienia optymalnego połączenia pomiędzy dwoma punktami sieci: $\{org, des\} \in VP \subseteq VS$, gdzie $\{org\}$ to wierzchołek początkowy ścieżki, a $\{des\}$ to punkt końcowy ścieżki. Para punktów $\{org, des\}$ jest utożsamiona z dowolną parą wierzchołków problemu ($nVRP^T$). Dodatkowo wierzchołek początkowy i końcowy charakteryzuje się oknem obsługi: $[e_i, l_i], \forall i \in \{org, des\} \in VP \subseteq VS$. Okna te są tożsame z oknami czasowymi modelu ($nVRP^T$).

Analogicznie jak w modelu ($nVRP^T$) każdemu łukowi (i, j) ze zbioru \mathbf{AS} przyporządkowano koszt w postaci macierzy: $\mathbf{TT}^{SP} = [tt_{ij}^{SP}]$, przy czym $tt_{ij}^{SP} \geq 0, \forall (i, j) \in \mathbf{AS} \wedge \forall \tau \in \mathbf{T}$, który reprezentuje czas przejazdu na odcinku drogowym (i, j) w danym τ interwale czasowym. Zakłada się, że czas przejazdu na każdym z łuków grafu jest funkcją od su: $[tt_{ij}^{SP}(\tau)] \equiv [tt_{ij}^{SP}]$, gdzie $tt_{ij}^{SP}(\tau)$ jest funkcją skokową i-tego wierzchołka ze zbioru \mathbf{VS} . Dodatkowo każdemu łukowi (i, j) ze zbioru \mathbf{AS} przyporządkowano koszt w postaci macierzy: $\mathbf{DD}^{SP} = [dd_{ij}^{SP}]$, przy czym $dd_{ij}^{SP} \geq 0, \forall (i, j) \in \mathbf{AS}$ która definiuje odległość pomiędzy węzłami (i, j) .

W oparciu o charakterystykę systemu transportu towarów oraz możliwość redukcji zależności od czasu, dynamizm zmiany czasu przejazdu na poszczególnych odcinkach sieci drogowej został uproszczony do postaci deterministycznej oznaczonej przez macierz czasu przejazdu: $\mathbf{TT}_{e_{org}}^{SP} = [tt_{ij}^{SP}(\tau_{e_{org}}): \forall (i, j) \in \mathbf{AS} \wedge \exists \tau_{e_{org}} \in \mathbf{T}: e_{org} \in]U_{\tau-1}, U_{\tau}[]$, gdzie $\tau_{e_{org}}$ jest indeksem interwału czasowego w zakresie, którego znajduje się początek okna czasowego e_{org} wierzchołka startowego org najkrótszej ścieżki. Innymi słowy, wartość czasu przejazdu na danym odcinku będzie pobierana przed procesem optymalizacji i będzie zależeć od początkowej wartości czasu okna czasowego wierzchołka startowego.

W modelu występują zmienne:

$x_{ij}^{SP} \in \{0,1\}$ - zmienna binarna określająca, czy dany łuk (i, j) znajduje się w rozwiązaniu (w ścieżce),

$f_1^{SP}, f_2^{SP} \in \mathbb{R}^+$ - zmienne definiujące cząstkowe kryteria funkcji celu: łączny czas przejazdu tras oraz łączny dystans tras,

$F_1^{SP}, F_2^{SP} \in [0,1]$ - znormalizowane zmienne, odpowiednio zmiennej f_1^{SP} oraz f_2^{SP} .

Podobnie jak w modelu ($nVRP1^T$), funkcja kryterialna jest znormalizowaną funkcją wypukłą, którą można zapisać w postaci:

$$(SPP^T): \min_{(F_1^{SP}, F_2^{SP})} (\omega^{SP} \cdot F_1^{SP} + (1 - \omega^{SP}) \cdot F_2^{SP}) \quad (4.29)$$

Ograniczenia wynikające z konstrukcji funkcji celu:

$$\left. \begin{aligned} F_1^{SP} &= \frac{f_1^{SP} - Fa_1^{SP}}{Fb_1^{SP} - Fa_1^{SP}} \\ f_1^{SP} &\geq \sum_{(i,j) \in \mathbf{AS}} x_{ij}^{SP} \cdot tt_{ij}^{SP}(\tau_{e_{org}}), \exists \tau_{e_{org}} \in \mathbf{T}: e_{org} \in (U_{\tau-1}, U_{\tau}] \end{aligned} \right\} \quad (4.30)$$

$$\left. \begin{aligned} F_2^{SP} &= \frac{f_2^{SP} - Fa_2^{SP}}{Fb_2^{SP} - Fa_2^{SP}} \\ f_2^{SP} &\geq \sum_{(i,j) \in \mathbf{AS}} x_{ij}^{SP} \cdot dd_{ij}^{SP} \end{aligned} \right\} \quad (4.31)$$

Ograniczenia wynikające z prawa zachowania strumienia:

$$\sum_{\{j:(i,j) \in \mathbf{AS}\}} x_{ij}^{SP} - \sum_{\{i:(i,j) \in \mathbf{AS}\}} x_{ij}^{SP} = \begin{cases} 1, & i = org \\ -1, & i = des \\ 0, & w p. p. \end{cases} \quad (4.32)$$

Charakterystyka zmiennych:

$$\begin{aligned} x_{ij}^{SP} &\in \{0,1\}, \forall (i,j) \in \mathbf{AS} \\ f_1^{SP}, f_2^{SP} &\in \mathbb{R}^+ \\ F_1^{SP}, F_2^{SP} &\in [0,1] \end{aligned} \quad (4.33)$$

Funkcja kryterialna (4.29) została zapisana w postaci znormalizowanej. Normalizacja została wprowadzona z uwagi na fakt dodawania dwóch różnych kryteriów charakteryzujących się różnymi jednostkami. Dzięki temu zabiegowi możliwe jest porównywanie różnych kryteriów. Zmienne Parametry Fa_1^{SP}, Fb_1^{SP} oznaczają, odpowiednio: minimalną/maksymalną długość trwania ścieżki dla danej sieci wyrażoną jednostką czasu. Natomiast parametry Fa_2^{SP}, Fb_2^{SP} oznaczają, odpowiednio: minimalną/maksymalną długość ścieżki w danej sieci, której kryterium był dystans. Zakłada się, że minimalne i maksymalne wartości poszczególnych funkcji przynależą do zbioru: $\mathbf{F}_N^{SP} = \{Fa_1^{SP}, Fa_2^{SP}, Fb_1^{SP}, Fb_2^{SP}\}$. Dodatkowy parametr ω^{SP} został wprowadzony w celu możliwości nadawania odpowiedniej wagi danemu członowi kryterium. Dzięki odpowiedniej formule wag, funkcja kryterialna jest wypukła. Ograniczenia (4.30) są odpowiednikiem znormalizowanego kryterium czasu przy założeniu, że czasy przejazdu w sieci zależą od początku okna czasowego wierzchołka startowego. Wyrażenia (4.31) definiują drugie znormalizowane kryterium modelu - minimalizacja łącznej długości ścieżki. Poprawność przepływu gwarantuje zależność (4.32), jest ona zapisana w standartowej i popularnie funkcjonującej formie. Ostatnie ograniczenia wynikają z określenia rodzaju zmiennych.

4.3.2 WERSJA ODPORNA NA WAHANIA PARAMETRÓW PROBLEMU NAJKRÓTSZEJ ŚCIEŻKI - R-SPP

W rozważaniach zakłada się, że niepewność wartości danych dotyczy czasów przejazdu na poszczególnych odcinkach sieci drogowej. Zatem, odnosząc się do modelu (SPP^T), niepewność parametrów występuje w ograniczeniach i będzie realizowana w macierzy \mathbf{TT}^{SP} . Zgodnie z założeniami przedstawionymi wcześniej niepewność wartości w macierzy czasów przejazdu będzie przyjmować wartości z symetrycznego przedziału: $\tilde{\mathbf{TT}}^{SP} = [\tilde{tt}_{ij\tau}^{SP}] = \{[\bar{tt}_{ij\tau}^{SP} - \hat{tt}_{ij\tau}^{SP}, \bar{tt}_{ij\tau}^{SP} + \hat{tt}_{ij\tau}^{SP}], \forall (i,j) \in \mathbf{AS} \wedge \forall \tau \in \mathbf{T}\}$. Macierz $\bar{tt}_{ij\tau}^{SP}$ jest reprezentacją wartości oczekiwanej czasu przejazdu w τ interwale czasowym dla każdego odcinka należącego do zbioru \mathbf{AS} . Analogicznie, macierz $\hat{tt}_{ij\tau}^{SP}$ będzie wartością odchylenia od wartości oczekiwanej w τ interwale czasowym dla każdego odcinka należącego do zbioru \mathbf{AS} . W najprostszej postaci wartością oczekiwaną może być średnia czasu przejazdu o danej porze dnia. Adaptując warunek o sposobie uwzględniania dynamizmu w modelu (SPP^T), zbiór niepewności w problemie R-SPP przyjmie postać:

$$\tilde{\mathbf{TT}}_{e_{org}}^{SP} = [\tilde{tt}_{ij}^{SP}(\tau_{e_{org}})] = \left\{ \left[\begin{array}{c} \bar{tt}_{ij}^{SP}(\tau_{e_{org}}) - \hat{tt}_{ij}^{SP}(\tau_{e_{org}}); \bar{tt}_{ij}^{SP}(\tau_{e_{org}}) + \hat{tt}_{ij}^{SP}(\tau_{e_{org}}) \\ \forall (i,j) \in \mathbf{AS} \wedge \exists \tau_{e_{org}} \in \mathbf{T}: e_{org} \in (U_{\tau-1}, U_{\tau}] \end{array} \right] \right\}$$

Macierz $\bar{tt}_{ij}^{SP}(\tau_{e_{org}})$ jest wartością oczekiwaną czasu przejazdu zależną od początku okna czasowego w wierzchołku startowym org . Analogicznie macierz $\hat{tt}_{ij}^{SP}(\tau_{e_{org}})$ jest in-

formacją o wartości możliwego odchylenia czasu przejazdu od wartości oczekiwanej dla danej pory dnia, w której znajduje się początek okna czasowego punktu startowego ścieżki org .

Przyjmując model niepewności wartości danych metody "niepewność w budżecie" (rozdział 3.3) do każdego wpisu macierzy czasu podróży, można włączyć dodatkową zmienną losową, niezależną $\boldsymbol{\eta}^{SP} = [\eta_{ij}^{SP}]$. Nowa formuła danych przybierze postać: $\tilde{c}t_{ij}^{SP}(e_{org}) = \bar{c}t_{ij}^{SP}(e_{org}) + \hat{c}t_{ij}^{SP}(e_{org}) \cdot \eta_{ij}^{SP} : \boldsymbol{\eta}^{SP} \in \mathcal{Z}^{SP}$, gdzie przez \mathcal{Z}^{SP} oznaczono zbiór niepewności problemu najkrótszej ścieżki, którego przestrzeń można zapisać: $\mathcal{Z}^{SP} = \{\boldsymbol{\eta}^{SP} \in \mathbb{R} : \|\boldsymbol{\eta}^{SP}\|_{\infty} \leq 1; \boldsymbol{\eta}^{SP} \mathbf{1} \leq \Gamma^{SP}\}$

Na podstawie modelu (SPP^T), przyjętych powyższych warunków oraz założeń metody "niepewność w budżecie" można sformułować model odporny na wahania parametrów dla problemu wyznaczania najkrótszych ścieżek przy uwzględnieniu dwóch kryteriów:

$$(RC_{SPP}): \min_{(F_1^{SP}, F_2^{SP})} (\omega^{SP} \cdot F_1^{SP} + (1 - \omega^{SP}) \cdot F_2^{SP}) \quad (4.34)$$

Przy ograniczeniach od (4.30) do (4.32) oraz:

$$(4.35)$$

$$f_1^{SP} \geq \sum_{(i,j) \in AS} x_{ij}^{SP} \cdot \bar{t}t_{ij\tau}^{SP}(\tau_{e_{org}}) +$$

$$\max_x \left\{ \sum_{(i,j) \in AS} x_{ij}^{SP} \cdot \hat{t}t_{ij}^{SP}(\tau_{e_{org}}) \cdot \eta_{ij}^{SP} : \sum_{(i,j) \in AS} \eta_{ij}^{SP} \leq \Gamma^{SP}, -1 \leq \eta_{ij}^{SP} \leq 1, (i,j) \in AS \right\}$$

Sens funkcji kryterialnej oraz ograniczeń od (4.30) do (4.32) jest taki sam jak w przypadku modelu (SPP). Ograniczenie (4.35) jest reprezentacją minimalizacji czasu trwania ścieżki przy uwzględnieniu niepewności czasu przejazdu. Ograniczenie to posiada w swoim zapisie parametr poziomu konserwatyizmu Γ^{SP} , który odpowiada za poziom stopnia realizacji niepewności parametrów modelu. Wartość jego wpływa na wielkość uwzględnianych odchyień we wszystkich odcinkach, które znajdują się w rozwiązaniu - ścieżce z punktu $\{org\}$ do punktu $\{des\}$.

Korzystając z ogólnego modelu (RC_{MIP}^e), ekwiwalentne sformułowanie odpowiednika modelu (RC_{SPP}) można zapisać jako problem programowania liniowego:

$$(RC_{SPP}^e): \min_{(F_1^{SP}, F_2^{SP})} (\omega^{SP} \cdot F_1^{SP} + (1 - \omega^{SP}) \cdot F_2^{SP}) \quad (4.36)$$

Przy ograniczeniach od (4.30) do (4.32) oraz:

$$f_1^{SP} \geq \sum_{(i,j) \in AS} x_{ij}^{SP} \cdot \bar{t}t_{ij\tau}^{SP}(\tau_{e_{org}}) + \theta^{SP} \cdot \Gamma^{SP} + \sum_{(i,j) \in AS} \alpha_{ij}^{SP} \quad (4.37)$$

$$\theta^{SP} + \alpha_{ij}^{SP} \geq \hat{t}t_{ij}^{SP}(\tau_{e_{org}}) \cdot y_{ij}^{SP}, \forall (i,j) \in AS \quad (4.38)$$

$$-y_{ij}^{SP} \leq x_{ij}^{SP} \leq y_{ij}^{SP}, \forall (i,j) \in AS \quad (4.39)$$

$$y_{ij}^{SP} \in \mathbb{R}^+ \wedge \alpha_{ij}^{SP} \in \mathbb{R}^+ \wedge \theta^{SP} \in \mathbb{R}^+, \forall (i, j) \in \mathbf{AS} \wedge e_{org} \in (U_{\tau-1}, U_{\tau}] \quad (4.40)$$

Znaczenie funkcja kryterialnej (4.36) jest takie samo jak w modelu (*SPP*). Ograniczenie (4.36) jest zlinearyzowaną wersją ograniczenia (4.35). Ograniczenia (4.37) oraz (4.38) są wynikiem implementacji silnego twierdzenia o dualności zastosowanej do wewnętrznej funkcji maksymalizacji zawartej w (4.35). Ostatnie dwa ograniczenia definiują zakres zmienności dodatkowych zmiennych dualnych.

4.4 DETERMINISTYCZNY PROBLEM OPTIMALIZACYJNY WYZNACZANIA TRAS POJAZDÓW UWZGLĘDNIAJĄCY ELASTYCZNE OKNA CZASOWE ORAZ PRZEPIŁYWY REWERSYJNE TOWARÓW - VRP-STW

Wynikiem rozważań poprzedniego podrozdziału jest koncepcja redukcji modelu zależnego od czasu. Uzasadniona, więc wydaje się konieczność przedstawienie obu wersji modeli ($nVRP1^T$) oraz ($nVRP2^T$), których wartości parametrów nie zależą od czasu. Analogicznie jak poprzednio, do matematycznego sformułowania skorzystano z programowania całkowitoliczbowego oraz teorii grafów. Różnica pomiędzy modelami ($nVRP1^T$) i ($nVRP2^T$), a zaprezentowanymi poniżej, występuje w: interpretacji łuków skierowanych grafu, przypisanych do nich charakterystyk oraz formie ograniczeń. Z tego powodu poniżej zaprezentowano tylko te elementy, które wymagały nowego sformułowania. Pozostała interpretacja składowych jest równoważna z oznaczeniami modeli ($nVRP1^T$) oraz ($nVRP2^T$).

Dany jest skierowany graf \mathbf{GP}^{VRP} , zdefiniowany przez uporządkowaną parę:

$$\mathbf{GP}^{VRP} = \langle \mathbf{VP}, \mathbf{AP}^{VRP} \rangle$$

gdzie:

$\mathbf{AP}^{VRP} = \{(i, j): i \neq j \wedge \forall i, j \in \mathbf{VP} \times \mathbf{VP}\}$ oznacza zbiór skierowanych łuków grafu, o interpretacji bezpośredniego połączenia pomiędzy węzłami sieci drogowej, wyrażonej poprzez najkrótszą ścieżką pomiędzy (i, j).

Zbiór \mathbf{AP}^{VRP} przyjmuje wartości określone binarnym odwzorowaniem na iloczynie kartezjańskim takie, że: $\zeta^{VRP}: \mathbf{VP} \times \mathbf{VP} \rightarrow \{0,1\}$, gdzie wielkość $VP(i, j) = 1, \forall i, j \in \mathbf{VP}$, gdy między węzłami (i, j) występuje najkrótsza ścieżka, w przeciwnym wypadku wielkość $\zeta^{VRP}(i, j) = 0, \forall i, j \in \mathbf{VP}: i = j$. Oznacza to, że zbiór połączeń \mathbf{AP}^{VRP} zapisany w postaci macierzy incydencji będzie macierzą pełną z zerami na przekątnej diagonalnej (nie istnieje połączenie z wierzchołkiem i do wierzchołkiem i). Wobec, czego graf \mathbf{GP}^{VRP} jest grafem pełnym, co warunkuje istnienie cyklu Hamiltona [157], przeciwnie niż to było w grafie \mathbf{GP} . Jest to podstawowa zaleta takiego sformułowania.

Każdemu łukowi (i, j) ze zbioru \mathbf{AP}^{VRP} przyporządkowano koszt w postaci macierzy: $\mathbf{TT}^{VRP} = [tt_{ij}^{VRP}]$, przy czym $tt_{ij}^{VRP} \geq 0, \forall (i, j) \in \mathbf{AP}^{VRP}$, który reprezentuje czas przejazdu na połączeniu (i, j). Każdy wpis macierzy \mathbf{TT}^{VRP} , reprezentuje wartość funkcji cząstkowej minimalizującej czas przejazdu najkrótszej ścieżki, co można zapisać, jako: $[f_1^{SP*}(i, j): \{i, j\} = \{org, des\} \subset \mathbf{VS}]$. Dodatkowo każdemu łukowi (i, j) ze zbioru \mathbf{AP}^{VRP}

przyporządkowano koszt w postaci macierzy: $\mathbf{DD}^{VRP} = [dd_{ij}^{VRP}]$, przy czym $dd_{ij}^{VRP} \geq 0, \forall (i, j) \in \mathbf{AP}$ która definiuje odległość pomiędzy wierzchołkami (i, j) . Analogicznie, każdy element macierzy \mathbf{DD}^{VRP} , reprezentuje wartość funkcji cząstkowej minimalizującej długość najkrótszej ścieżki, co można zapisać, jako: $[f_2^{SP*}(i, j): \{i, j\} = \{org, des\} \subset \mathbf{VS}]$. Tak samo jak w modelu $(nVRP^T)$ dokonywana jest transformacja grafu oraz przypisanych mu macierzy kosztów, poprzez dodanie K-tej liczby wirtualnych powrotnych magazynów. Wobec czego oznaczenia tych elementów przyjmą postać: $\mathbf{GP}^{VRP} \rightarrow \mathbf{GP}_K^{VRP}$, $\mathbf{AP}^{VRP} \rightarrow \mathbf{AP}_K^{VRP}$, $\mathbf{TT}^{VRP} \rightarrow \mathbf{TT}_K^{VRP}$ oraz $\mathbf{DD}^{VRP} \rightarrow \mathbf{DD}_K^{VRP}$.

Model problemu wyznaczania tras pojazdów uwzględniający elastyczne okna czasowe i przepływy rewersyjne towarów z założeniem stałej liczby pojazdów zawiera zmienne decyzyjne:

$x_{ij}^{VRP} \in \{0,1\}$ - zmienna binarna określająca, czy dany łuk (i, j) znajduje się w rozwiązaniu,

$df_{ij}^{VRP} \geq 0$ - zmienna określająca ilość towaru rozwożonego, znajdującego się w pojeździe przejeżdżającego przez łuk (i, j) - przepływ towarów w przód,

$sf_{ij}^{VRP} \geq 0$ - zmienna określająca ilość towaru zbieranego, znajdującego się w pojeździe przejeżdżającego przez łuk (i, j) - przepływ rewersyjny,

$ta_i^{VRP} \geq 0$ - oznacza czas przyjazdu pojazdu do i-tego klienta - jest to moment rozpoczęcia obsługi klienta,

$f_i^{VRP} \geq 0$ - wartość i-tego kryterium cząstkowego funkcji celu,

$F_i^{VRP} \geq 0$ - znormalizowana wartość i-tego kryterium cząstkowego funkcji celu, obliczana przez normalizację min-max: $F_i^{VRP} = \frac{f_i^{VRP} - Fa_i^{VRP}}{Fb_i^{VRP} - Fa_i^{VRP}}, i = 1, \dots, 4$.

Funkcja kryterialna jest sumą znormalizowanych, cząstkowych kryteriów, której zapis przedstawia się następująco:

$$(nVRP1): \min_{F_i^{VRP}} \sum_{i=1}^4 \omega 1_i \cdot F_i^{VRP} \quad (4.41)$$

Ograniczenia wynikające z kryteriów cząstkowych:

$$f_1^{VRP} \geq \sum_{(i,j) \in \mathbf{AP}_K^{VRP}} x_{ij}^{VRP} \cdot tt_{ij}^{VRP} \quad (4.42)$$

$$f_2^{VRP} \geq \sum_{(i,j) \in \mathbf{AP}_K^{VRP}} x_{ij}^{VRP} \cdot dd_{ij}^{VRP} \quad (4.43)$$

$$f_3^{VRP} \geq \sum_{i \in \mathbf{VP}_c} (e_i - ta_i^{VRP})^+ \quad (4.44)$$

$$f_4^{VRP} \geq \sum_{i \in \mathbf{VP}_c} (ta_i^{VRP} - l_i)^+ \quad (4.45)$$

Ograniczenia definiujące poprawność przepływu:

$$\sum_{i \in VP} x_{ij}^{VRP} = 1, \quad \forall j \in VP_K \setminus \{1\} \quad (4.46)$$

$$\sum_{j \in VP_k \setminus \{1\}} x_{ij}^{VRP} = 1, \quad \forall i \in VP_c \quad (4.47)$$

$$\sum_{j \in VP_c} x_{ij}^{VRP} = K \quad (4.48)$$

Ograniczenia pojemnościowe:

$$\sum_{j \in VP_k} df_{ji}^{VRP} - \sum_{j \in VP_k} df_{ij}^{VRP} = d_i, \quad \forall i \in VP_c \quad (4.49)$$

$$\sum_{j \in VP_k} sf_{ij}^{VRP} - \sum_{j \in VP_k} sf_{ji}^{VRP} = s_i, \quad \forall i \in VP_c \quad (4.50)$$

$$df_{ij}^{VRP} + sf_{ij}^{VRP} \leq Q \cdot x_{ij}^{VRP}, \quad \forall (i, j) \in AP_K^{VRP} \quad (4.51)$$

Ograniczenia związane z oknami czasowymi:

$$ta_i^{VRP} + st_i + tt_{ij}^{VRP} - ta_j^{VRP} - (1 - x_{ij}^{VRP}) \cdot b1_{ij}^{VRP} \leq 0, \quad \forall i \in VP; \forall j \in VP_k \setminus \{1\}; i \neq j \quad (4.52)$$

$$ta_i + st_i + tt_{ij}^{VRP} - ta_j^{VRP} - (x_{ij}^{VRP} - 1) \cdot b2_{ij}^{VRP} \geq 0, \quad \forall i \in VP; \forall j \in VP_k \setminus \{1\}; i \neq j \quad (4.53)$$

$$e_i^\# \leq ta_i^{VRP} \leq l_i^\#, \quad \forall i \in VP_K \quad (4.54)$$

Natura zmiennych:

$$x_{ij}^{VRP} \in \{0,1\}, \quad \forall (i, j) \in AP_K^{VRP} \quad (4.55)$$

$$df_{ij}^{VRP} \in \mathbb{R}^+, \quad \forall (i, j) \in AP_K^{VRP}$$

$$sf_{ij}^{VRP} \in \mathbb{R}^+, \quad \forall (i, j) \in AP_K^{VRP}$$

$$ta_i^{VRP} \in \mathbb{R}^+, \quad \forall i \in VP_K$$

$$f_i^{VRP} \in \mathbb{R}^+, i = 1, \dots, 4$$

$$F_i^{VRP} \in [0,1], i = 1, \dots, 4$$

Sens i znaczenie ograniczeń modelu ($nVRP1$) jest analogiczne jak w modelu ($nVRP1^T$), pominięta jest tylko kwestia zależności od czasu. Zakłada się, że zakres zmienności cząstkowych funkcji kryterialnych (minimalne i maksymalne wartości) przynależą do zbioru: $F_{N1}^{VRP} = \{(Fa_i^{VRP}, Fa_i^{VRP}): Fa_i^{VRP}, Fa_i^{VRP} \in \mathbb{R}^+, i = 1, \dots, 4\}$. Z uwagi, że powyższy model jest elementem składowym koncepcji integracji problemu R-SPP z problemami VRP, wartości wag preferencji kryteriów cząstkowych ω_1 są takie same jak w modelu ($VRP1^T$).

Druga wersja problemu VRP-STW zakłada, że liczba pojazdów jest zmienna. Aby wprowadzić możliwość użycia, co najmniej K -tą liczbę pojazdów należy zamienić ograniczenia (4.46) oraz (4.48), analogicznie jak w modelu ($VRP2^T$). Sens zmiennych, oznaczeń w poniż-

szej wersji modelu jest taki sam jak w modelu (*nVRP1*). Funkcja kryterialna przyjmie postać minimalizacji pięciu znormalizowanych kryteriów cząstkowych, co można zapisać następująco:

$$(nVRP2): \min_{F_i^{VRP}} \sum_{i=1}^5 \omega 2_i \cdot F_i^{VRP} \quad (4.56)$$

Ograniczenia związane z funkcją celu (4.42) do (4.45) oraz:

$$f_5^{VRP} \geq \sum_{j \in VP_c} x_{1j}^{VRP} \quad (4.57)$$

$$f_5^{VRP} \in \mathbb{Z}$$

$$F_5^{VRP} \in [0,1]$$

Ograniczenia związane z poprawnym przepływem w grafie definiują ograniczenia (4.47) oraz:

$$\left. \begin{array}{l} \sum_{i \in VP} x_{ij}^{VRP} = 1, \quad \forall j \in VP_c \\ \sum_{i \in VP} x_{ij}^{VRP} \leq 1, \quad \forall j \in VP_k \setminus VP \end{array} \right\} \quad (4.58)$$

$$\left. \begin{array}{l} \sum_{j \in VP_c} x_{1j}^{VRP} \geq 1 \\ \sum_{j \in VP_c} x_{1j}^{VRP} \leq K \end{array} \right\} \quad (4.59)$$

Pozostałe ograniczenia modelu to zależności od (4.49) do (4.55).

Znormalizowane kryterium cząstkowe F_5^{VRP} oznacza minimalizację liczby użytych pojazdów w rozwiązaniu. Zakłada się, że zakres zmienności cząstkowych funkcji kryterialnych (minimalne i maksymalne wartości) przynależą do zbioru:

$F_{N2}^{VRP} = \{(Fa_i^{VRP}, Fa_i^{VRP}): Fa_i^{VRP}, Fa_i^{VRP} \in \mathbb{R}^+, i = 1, \dots, 5\}$. Z uwagi, że powyższy model jest elementem składowym koncepcji integracji problemu R-SPP z problemami VRP, wartości wag preferencji kryteriów cząstkowych $\omega 1_i$ są takie same jak w modelu (*VRP2^T*). Ograniczenia (4.58) oraz (4.59) zapewniają, że liczba pojazdów jest zmienna i maksymalnie może być równa wartości K .

W procesie optymalizacji otrzymywane jest rozwiązanie, które można utożsamiać z harmonogramem dostaw. Występuje w nim: przydział danego klienta do trasy, sekwencja obsługi klientów przez kierowcę oraz przewidywany czas przyjazdu kierowcy i czas obsługi. Natomiast bezpośrednim wynikiem nie jest przypisanie danej trasy do konkretnego kierowcy. W praktyce, rozwiązanie problemu marszrutyzacji powinno być poddane procesowi harmonogramowania, którego wynikiem będzie pełny harmonogram dostaw. Jest to zdeterminowane przez warunki problemów VRP, przede wszystkim ograniczenia wynikające z istnienia okien czasowych obsługi klientów. Stąd w dalszej części pracy, w odniesieniu do rozwiązań problemów VRP będzie stosowane pojęcie trasy, a nie pojazdu³³.

³³ Autor do tej pory stosował pojęcie "pojazd" z uwagi na popularność występowania takiego określenia w literaturze przedmiotu.

Do danego pojazdu można przypisać kilka tras, które w kontekście pierwotnych ograniczeń problemu VRP może wydawać się niedopuszczalne. Dla przykładu, w założeniach problemu marszrutyzacji założono, że maksymalnie czas opóźnienia lub wczesnego przyjazdu do klienta to 15 min. W drodze optymalizacji otrzymano dwie trasy: pierwsza, w której ostatni klient do obsłużenia to X i druga, w której pierwszy klienta to Y. Najpóźniejszy czas obsługi klienta X to 12:00 plus ewentualne 15 min opóźnienia, a czas obsługi to 5 min. Najwcześniejszy czas rozpoczęcia obsługi u klienta Y to 13:00 minus 15 min wcześniejszego przyjazdu. Czas dojazdu z X do Y to 10 min. Z perspektywy zapisu modelu i wprowadzonych danych, tras tych nie można połączyć, bo pojazd obsługując klienta X z pierwszej trasy, najpóźniej mógłby przyjechać do klienta Y z drugiej trasy o 12:30 (12:00+15min+5min+10min), czyli 15 min przed otwarciem się elastycznego okna obsługi klienta Y. Z punktu widzenia praktycznego firmy, takie trasy mogą być obsłużone przez jeden pojazd (pod warunkiem spełnienia ograniczeń pojemnościowych). Oczywiście możliwe jest automatyczne uwzględnianie w modelu VRP takich potencjalnych połączeń pomiędzy klientami. W takich przypadkach należałoby zrezygnować z ograniczenia 4.53, które gwarantuje, że kierowca nie będzie oczekiwał w węzłach grafu, więcej niż wynikałoby to z elastycznych okien czasowych. Jednakże takie modele dają w rezultacie rozwiązania, w których łączny czas oczekiwania kierowcy jest duży, co nie jest pożądanie przez firmy transportowe. W kontekście zaprezentowanych modeli VRP, parametr K będzie więc oznaczać maksymalną liczbę tras (pierwotnie utożsamioną z posiadaną liczbą pojazdów), jaka może znaleźć się w rozwiązaniu, a przez oznaczenie K^* będzie zdefiniowana liczba tras uzyskanych w wyniku optymalizacji danego przykładu.

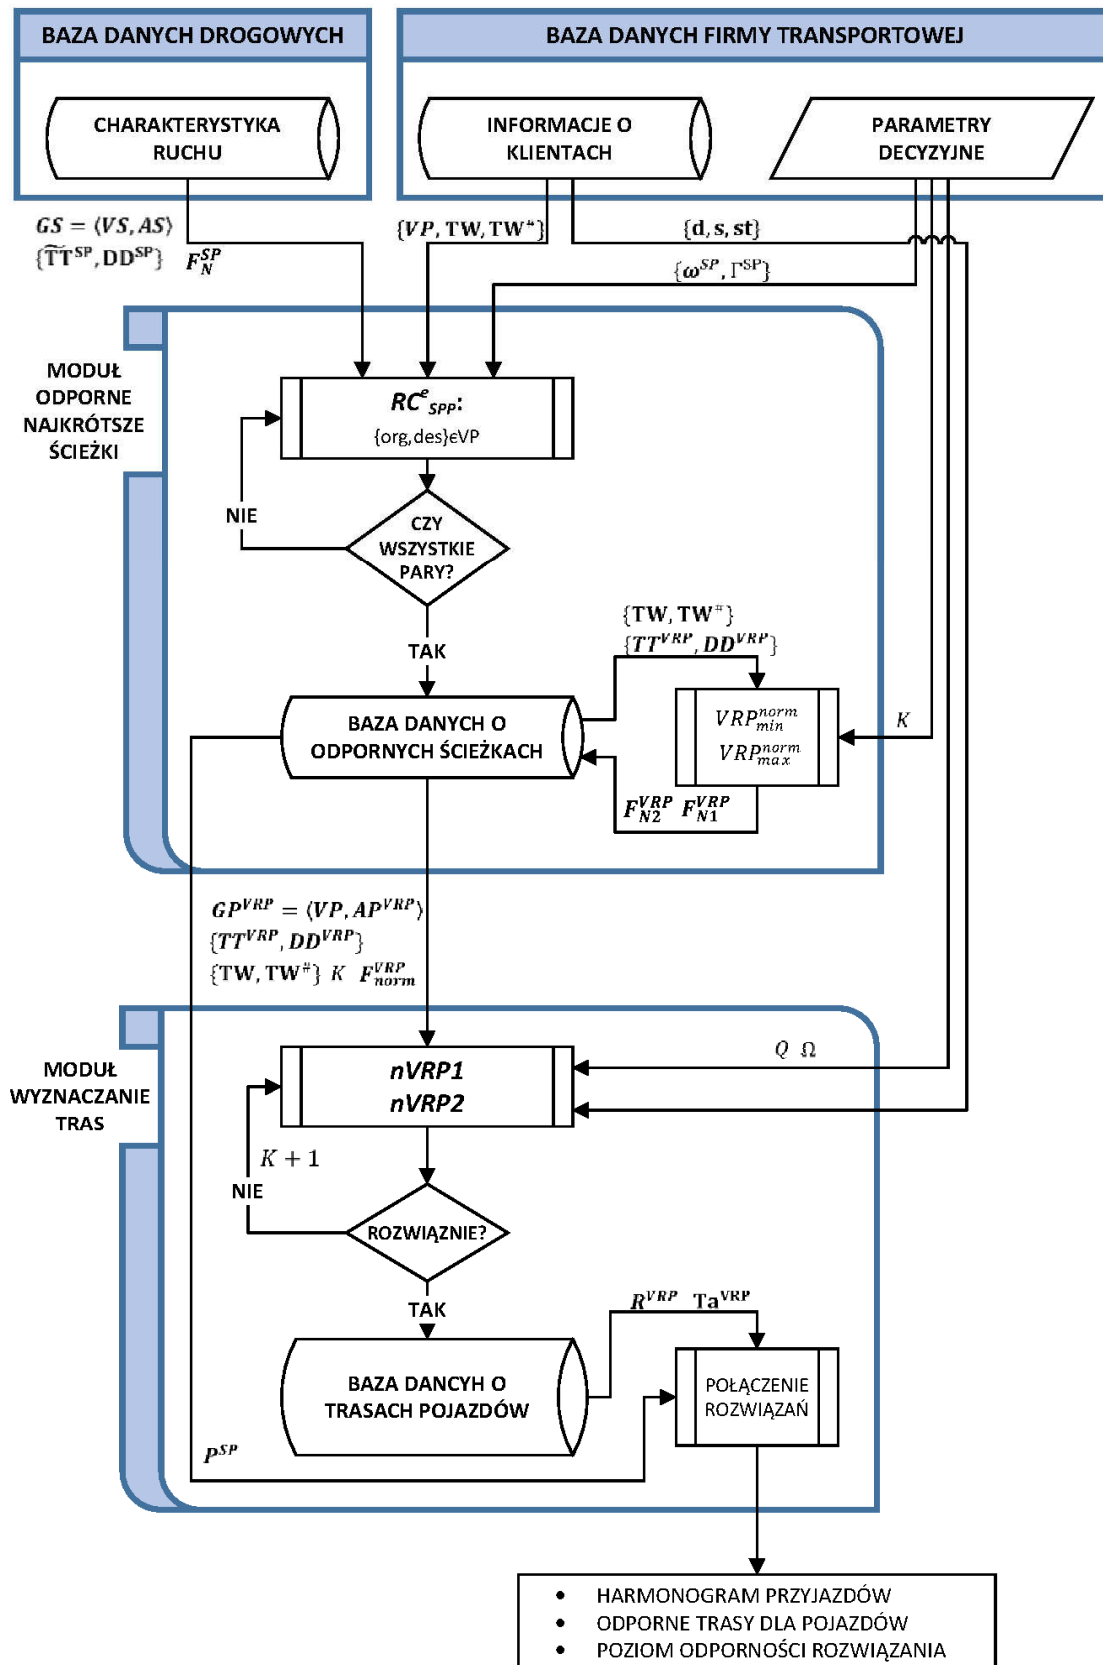
Dość istotnym elementem obu powyższych sformułowań są macierze "dużych liczb": $\mathbf{B1}^{VRP} = [b1_{ij}^{VRP}]$ oraz $\mathbf{B2}^{VRP} = [b2_{ij}^{VRP}]$, od której wartości w dużej mierze zależy przebieg optymalizacji. Zbyt wysokie wartości będą prowadzić do utworzenie większej przestrzeni poszukiwań rozwiązania przez algorytm optymalizacyjny, a co za tym idzie, zwiększenia czasu optymalizacji. Zbyt małe wartości będą powodować, że zbiór rozwiązań dopuszczalnych będzie pusty, czyli rozwiązanie nie będzie istniało. Określenie wartości elementów macierzy $\mathbf{B1}^{VRP}$ i $\mathbf{B2}^{VRP}$ powinno być dobrane indywidualnie nie tylko do danego problemu, ale również do każdego ograniczenia, jakie zostanie wygenerowane na podstawie warunku (4.52) oraz (4.53). Stąd w zapisie użyto postaci macierzowej³⁴. Macierz "dużych liczb" $\mathbf{B1}^{VRP}$ można uzyskać przez obliczenie: $b1_{ij}^{VRP} = \max \{0; l_i + st_i + tt_{ij}^{VRP} - e_j\}, \forall (i, j) \in \mathbf{AP}_K^{VRP}$, a dla macierzy $\mathbf{B2}^{VRP}$ elementy wynoszą: $b2_{ij}^{VRP} = \max \{0; l_j + st_j - tt_{ij}^{VRP} - e_i\}, \forall (i, j) \in \mathbf{AP}_K^{VRP}$.

³⁴ W niektórych modelach w literaturze przedmiotu można odnaleźć zastosowanie tylko skalarnej wartości tzw. "dużej liczby". Jednak z punktu widzenia procesu optymalizacji, nie jest to zbyt efektywne podejście [145] [146].

4.5 PRZEPIY W DANYCH W METODYCE OPTYMALIZACJI ZAGADNIEN WYZNACZANIA TRAS POJAZDOW

Dla zobrazowania powyższych rozważań, wprowadzonych założeń oraz zaproponowanych koncepcji na rysunku 4.5 zaprezentowano przepływ najważniejszych danych. Obieg danych dotyczy rozwiązywania problemu wyznaczania odpornych tras pojazdów typu R-TD-VRP-STW.

Baza danych drogowych to m.in. informacje na temat sieci drogowej, czasu przejazdu na poszczególnych odcinkach oraz związanym z nim poziomem niepewności. W bazie tej znajdują się również informacje dotyczące parametrów wykorzystywanych do normalizacji funkcji kryterialnej modelu (RC_{SP}^e). Wartości parametrów F_N^{SP} są wyznaczane indywidualnie dla każdego z analizowanych obszarów w obrębie, których rozważa się oryginalny problem wyznaczania tras pojazdów. Minimalne wartości zbioru oznaczają najmniejszą długość ścieżki w danej sieci wyrażoną czasem i dystansem, czyli de facto jest to najmniejszy czas przejazdu lub najmniejszą odległość w macierzach: \widetilde{TT}^{SP} oraz DD^{SP} , odpowiednio. Z kolei maksymalne wartości zbioru F_N^{SP} oznaczają maksymalną ścieżkę w sieci biorąc pod uwagę osobno, czas i dystans. Na tym etapie niepewność czasu przejazdu jest określona poprzez zakres zmienności danych.



Rysunek 4.5. Przepływ danych w koncepcji integracji problemu R-SPP z normalizowanym problemem VRP-STW.

Źródło: opracowanie własne.

Drugą bazą danych są informacje firmy transportowej na temat klientów: lokalizacja oraz charakterystyka obsługi. Dodatkowymi informacjami są parametry decyzyjne: liczba pojazdów przypisanych do obsługi, pojemność pojazdów, wagi kryteriów cząstkowych oraz wielkość parametru konserwatywności. Parametr Γ^{SP} to drugi punkt określania poziomu niepewności danych, należący do procesu decyzyjnego firmy transportowej. Wartość tego parametru może być określana każdorazowo przez decydenta np. planistę transportu lub program do wspomagania decyzji. Dodatkowo możliwe jest zwiększanie szerokości zbioru niepewności określonego w $\widetilde{\mathbf{TT}}^{SP}$, w zależności od konkretnych warunków decyzyjnych. Taka zmiana oznaczać będzie, że decydent otrzyma rozwiązanie odporne na wahania wartości parametrów.

Z uwagi, że moduł obliczający odporne ścieżki jest integralnym elementem metody rozwiązywania odpornego problemu wyznaczania tras, relacje pomiędzy kryteriami modelu (RC_{SPP}^e) muszą być takie same jak w modelu $(nVRP^T)$. Model (RC_{SPP}^e) uwzględnia dwa pierwsze kryteria, a więc biorąc pod uwagę własność funkcji wypukłej przedstawionej w (4.23), waga kryterium w (RC_{SPP}^e) wyniesie: $\omega^{SP} = \frac{\omega_{11}}{\omega_{11} + \omega_{12}}$ lub $\omega^{SP} = \frac{\omega_{21}}{\omega_{21} + \omega_{22}}$, w zależności od przyjętej wersji problemu VRP-STW.

W module odporne najkrótsze ścieżki, proces obliczania ścieżek odpornych jest wykonywany dla każdej pary wierzchołków ze zbioru \mathbf{VP} . Na podstawie obliczeń zostaje utworzona baza danych, w której zawarte są informacje na temat: wartości czasu przejazdu pomiędzy każdą parą klientów \mathbf{TT}^{VRP} wyznaczone w oparciu o okno czasowe obsługi klienta i niepewność wahań danych; macierzy odległości pomiędzy każdą parą klientów \mathbf{DD}^{VRP} , reprezentujące długość najkrótszej odpornej ścieżki; zbiór odpornych ścieżek \mathbf{P}^{SP} . W bazie tej aktualizowane są również parametry normalizujące poszczególne cząstkowe funkcje kryterialne. Wartości zbiorów $\mathbf{F}_{N1}^{VRP}, \mathbf{F}_{N2}^{VRP}$ są uzyskiwane dla każdej bazy danych indywidualnie i mogą przyjmować następujące wartości:

- Fa_1^{VRP} - wartość funkcji celu modelu (VRP_{min}^{norm}) przy $\beta = 1$,
- Fa_2^{VRP} - wartość funkcji celu modelu (VRP_{min}^{norm}) przy $\beta = 0$,
- $Fa_3^{VRP} = Fa_4^{VRP} = 0$,
- $Fa_5^{VRP} = 1$,
- Fb_1^{VRP} - wartość funkcji celu modelu (VRP_{max}^{norm}) przy $\beta = 1$,
- Fb_2^{VRP} - wartość funkcji celu modelu (VRP_{max}^{norm}) przy $\beta = 0$,
- $Fb_3^{VRP} = \sum_{i \in \mathbf{VP}_c} (e_i - e_i^\#)$,
- $Fb_4^{VRP} = \sum_{i \in \mathbf{VP}_c} (l_i^\# - l_i)$,
- $Fb_5^{VRP} = K$.

Model (VRP_{min}^{norm}) dla wyznaczania dolnej i górnej granicy zmienności kryterium czasu oraz kryterium dystansu został zaprezentowany w załączniku A. Został on zdefiniowany w uniwersalnej formie, tak aby w zależności od potrzeb można było wyznaczyć minimalne/maksymalne zakresy zmian kryterium czasu ($\beta = 1$) lub kryterium dystansu ($\beta = 0$).

Dane z bazy danych modułu odpornych ścieżek są przesyłane do modułu wyznaczania tras pojazdom. Wykorzystując model $(nVRP1)$ lub $(nVRP2)$ otrzymywane są trasy pojazdów, które są zawarte w zbiorze: \mathbf{R}^{VRP} . Trasy te określają sekwencję odwiedzania klientów oraz czasy przyjazdów pojazdów do poszczególnych klientów, które można opisać wektorem:

$\mathbf{Ta}^{VRP} = [ta_i^{VRP}]$, $\forall i \in VP_K$. W celu uzyskania dokładnego przebiegu tras konieczne jest połączenie zbiorów rozwiązań obu modułów.

Zaprezentowany na rysunku powyżej przepływ danych jest jednocześnie pogładową strukturą połączeń informatycznych funkcji programu MATLAB, które zostały napisane przez autora tej pracy. Jak to już zostało wspomniane funkcje te zostały napisane przy użyciu funkcjonalności programu MATLAB oraz dodatku ROME 1.09. Dodatek ten umożliwia łatwą implementację modeli matematycznych w postaci składni językowej programu MATLAB oraz na komunikację z zewnętrznym programem optymalizacyjnym. Optymalizacja została wykonana przy użyciu programu CPLEX 12. Komunikacja programu MATLAB oraz CPLEX, czyli eksport problemu oraz import rozwiązania występuje w trzech blokach obliczeniowych: najkrótszych ścieżek dla każdej pary (element (RC_{SPP}^e)), wyznaczenia zakresu zmienności kryteriów cząstkowych (element (VRP_{min}^{norm}) , (VRP_{max}^{norm})) oraz problemu wyznaczenia tras (element $(nVRP1)$, $(nVRP2)$).

4.6 WNIOSKI Z ROZDZIAŁU NR 4

W rozdziale zaprezentowano matematyczny model dla wybranego wielokryterialnego problemu wyznaczania tras pojazdów: TD-VRP-STW. Ze względu na swoją charakterystykę i złożoność próba implementacji losowych parametrów, które definiują niepewność wartości czasu przejazdu bezpośrednio do modelu nie ma praktycznego uzasadnienia. Możliwość ujęcia zmienności czasu przejazdu została wprowadzona przez propozycję połączenia (integracji) dwukryterialnego odpornego problemu najkrótszej ścieżki R-SPP z wielokryterialnym deterministycznym problemem wyznaczania tras pojazdów VRP-STW. Takie sformułowanie problemu jest dekompozycją problemu bardziej złożonego, a mianowicie wielokryterialnego problemu wyznaczania tras pojazdów z uwzględnieniem niepewności parametrów: R-TD-VRP-STW. Podstawowymi zaletami takiego podejścia są:

- zmniejszenie złożoności obliczeniowej,
- możliwość rozproszenia wykonywanych obliczeń na kilka równoległych procesów,
- uwzględnienie charakterystyki zmienności każdego z odcinków sieci drogowej osobno,
- możliwość redukcji problemów zależnych od czasu do statycznych,
- możliwość aktualizacji tylko części bazy danych o najkrótszych ścieżkach,
- możliwość przeniesienia na dowolną odmianę zagadnienia wyznaczania tras.

Efektom dekompozycji problemu R-TD-VRP-STW są: odporne trasy pojazdów, harmonogram przyjazdów i odjazdów poszczególnych pojazdów u klientów oraz informacja o poziomie uodpornienia uzyskanych rozwiązań. Jeśli w trakcie realizacji dystrybucji towarów czasy przejazdu w sieci drogowej będą się zmieniać w granicach zmienności określonej przez afiniczną postać $\hat{\mathbf{T}}^{SP}$, rozwiązanie wciąż będzie optymalne w sensie odpornym. Większe odchylenia od średniej mogą być przyczyną do rozważania tzw. re-optymalizacji tras, jednak tematyka ta jest osobną kwestią, niezwiązaną z rozważaniami pracy. Jednak jak pokazują to symulacje w następnym rozdziale, przekroczenie zbioru niepewności posiada pozytywne aspekty. Charakterystykę zaprezentowanych modeli matematycznych oraz koncepcję dekompozycji problemu TD-VRP-STW przedstawiono w kolejnym rozdziale pracy.

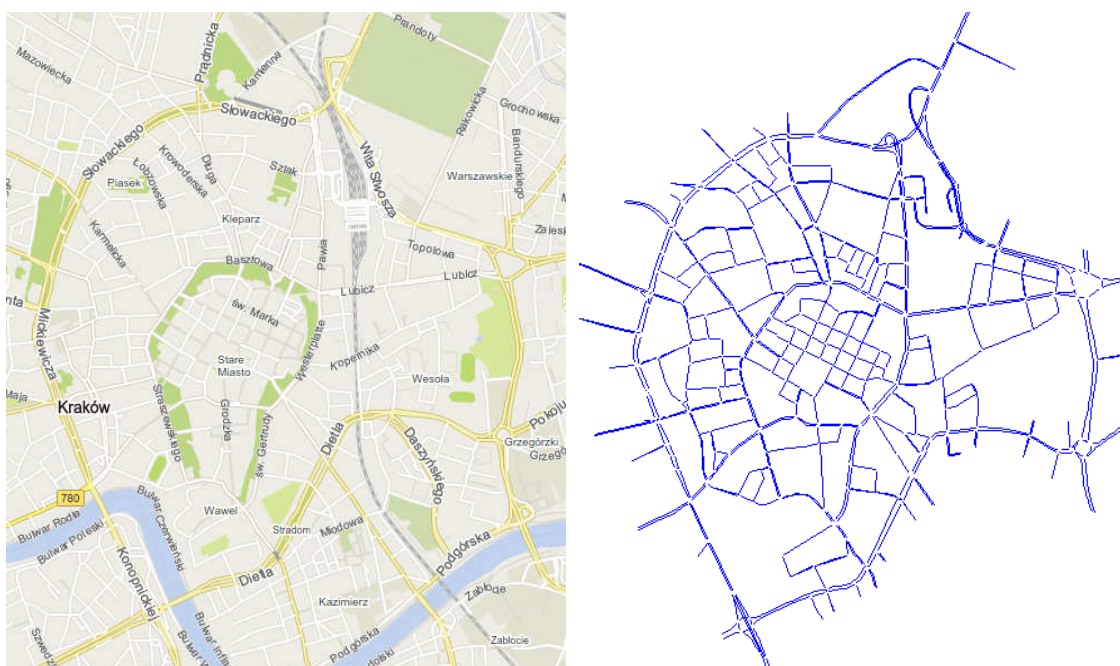
5 SYMULACJE KOMPUTEROWE I ANALIZA PROPONOWANYCH MODELI MATEMATYCZNYCH

5.1 SPECYFIKACJA WYBRANEJ SIECI DROGOWEJ

Istotnym elementem wykonywanych obliczeń komputerowych są dane, które mają na celu weryfikację założonych modeli matematycznych. Przydatność danego modelu matematycznego, często w dużej mierze zależy od reprezentatywnych danych oraz relacji występujących wewnątrz nich, np. stosunek wariancji do wartości średniej. W rozprawie doktorskiej analizie modeli zagadnienia wyznaczania tras pojazdom zostały wykonane w oparciu o dane uzyskane z symulatora ruchu drogowego AIMSUN 8.1. Program ten jest zintegrowanym pakietem do wykonywania mikro-, mezo- oraz makroskopowych symulacji ruchu drogowego. Charakterystykę czasu przejazdu otrzymano przy pomocy symulacji mikroskopowej ruchu drogowego, skalibrowanej w oparciu o rzeczywiste pomiary.

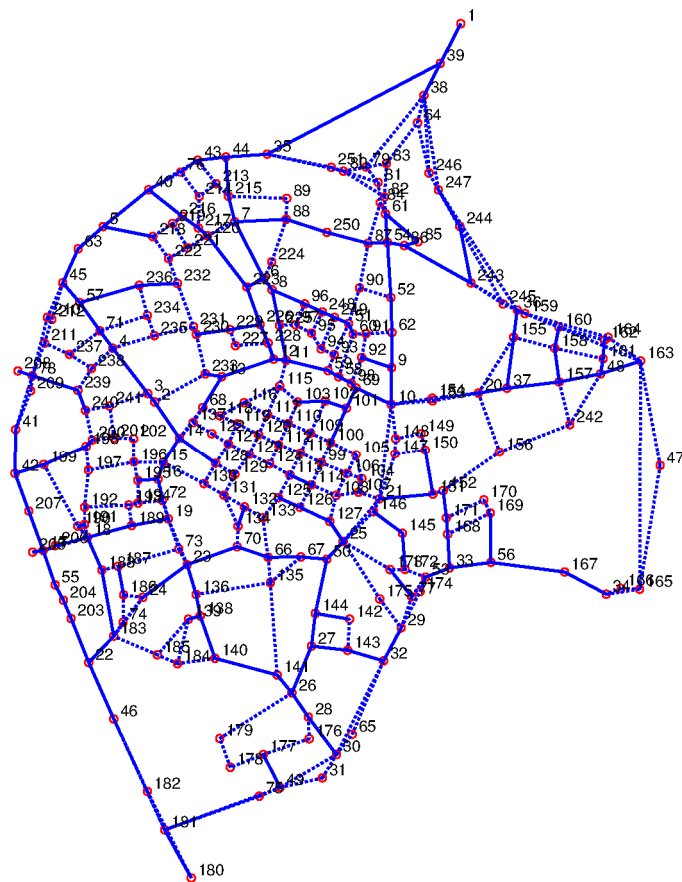
5.1.1 WYBRANY OBSZAR MIEJSKI

Do analiz wybrano sieć drogową znajdującą się na obszarze centrum miasta Krakowa, wytyczony w dużej części przez tzw. "drugą obwodnicę" miasta (rysunek 5.1). Analizowana sieć drogową przekształconą do postaci grafu skierowanego składa się z 251 wierzchołków (w głównej mierze są to skrzyżowania) oraz 564 łuków (odcinków drogowych). Na rysunku 5.2 przedstawiono wspomniany graf wraz zaznaczeniem łuków jednokierunkowych (linia przerywana), łuków dwukierunkowych (linia ciągła) oraz numeracji kolejnych punktów grafu.



Rysunek 5.1 Analizowany obszar miasta Krakowa (po lewej) oraz jego model w programie AIMSUN (po prawej).

Źródło: opracowanie własne na podstawie <https://maps.google.pl>



Rysunek 5.2 Graf analizowanej sieci miasta Krakowa.

Linia ciągła - odcinki dwukierunkowe, linia przerywana - odcinki jednokierunkowe.

Źródło: opracowanie własne.

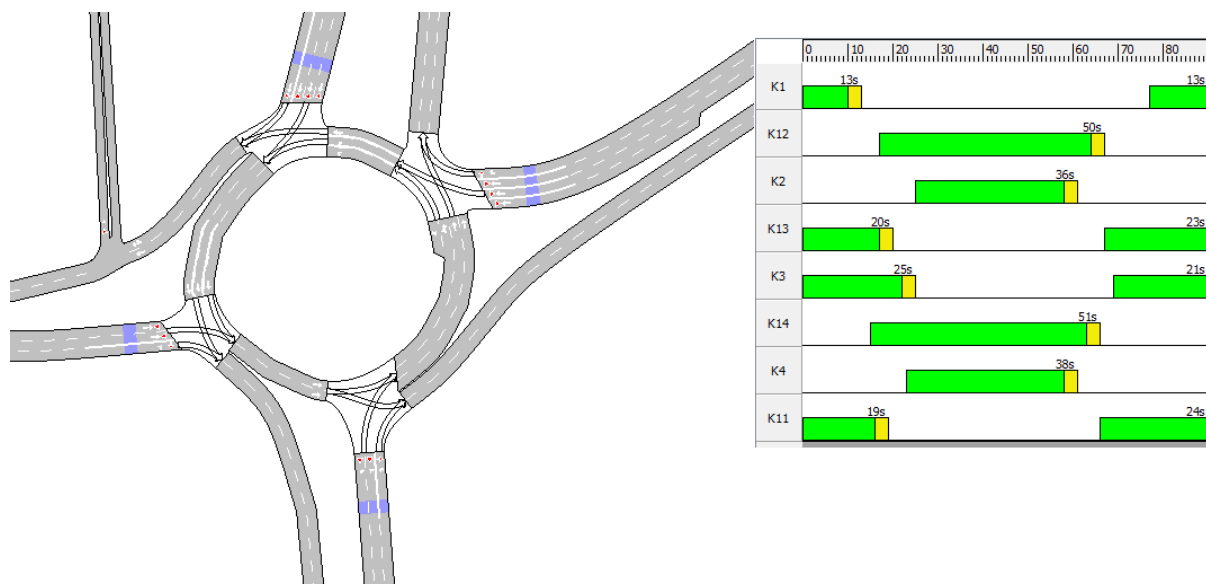
5.1.2 PROCES TWORZENIA MODELU MIKROSKOPOWEGO

Proces modelowania sieci drogowej zaprezentowanej na rysunku 5.1 składał się z następujących kroków:

1. Określenie charakterystyki infrastruktury drogowej
2. Pozyskanie rzeczywistych danych charakteryzujących dany ruch drogowy,
3. Budowa modelu symulacyjnego w programie,
4. Wprowadzenie danych oraz wykonanie rozkładu ruchu drogowego w oparciu o makroskopową symulację,
5. Weryfikacja modelu w celu określenia użyteczności modelu i danych,
6. Wykonanie kalibracji macierzy podróży O-D (macierz źródło-cel),
7. Wykonanie pilotażowej symulacji mikroskopowej,
8. Ocena zgodności modelu,
9. Modyfikacja parametrów programu symulacyjnego,
10. Zakończenie kalibracji lub ponowne wykonanie kroków 7,8 i 9.

Pierwsze trzy kroki obejmowały etapy budowy modelu w oparciu o specyfikę analizowanego obszaru oraz dostępne dane rzeczywiste. Z uwagi na fakt wykonywania symulacji mikroskopowej konieczne było zachowanie wysokiego poziomu odzwierciedlenia modelu. Prace modelowe obejmowały określenie i zdefiniowanie m.in.: charakterystyki poszczególnych skrzyżowań (liczba pasów, pierwszeństwo przejazdu, kształt przebiegu trasy przejazdu pojaz-

dów przez tarczę skrzyżowania, oznakowanie poziome, itp.), lokalizacji detektorów (indukcyjnych czujników pętlowych), planów sygnalizacji świetlnej oraz kategorii odcinków drogowych. Plany sygnalizacji oraz powiązane z nimi pętle indukcyjne zostały wprowadzone na podstawie map podkładowych oraz wydruków ze sterowników sygnalizacji świetlnej skrzyżowań uzyskanych od Zarządu Infrastruktury Komunalnej i Transportowej w Krakowie (dalej ZIKIT). Przykładowe skrzyżowanie (Rondo Grzegórzeckie) oraz projekt planu sygnalizacji świetlnej przedstawia rysunek 5.3.



Rysunek 5.3 Przykładowy model skrzyżowania oraz projekt planu sygnalizacji świetlnej (po prawej) w programie Aimsun.

Źródło: opracowanie własne.

Jedną z najważniejszych informacji potrzebnych do odzwierciedlenia rzeczywistych sieci drogowych w symulatorze są dane o charakterystyce ruchu. Do określenia charakterystyki ruchu drogowego w analizowanej sieci drogowej wybrano trzy źródła danych. Pierwsze z nich to badania pt. "Badania zachowań komunikacyjnych mieszkańców Krakowskiego Obszaru Metropolitalnego wraz z opracowaniem zunifikowanej metodyki badań i modelowania ruchu dla Krakowskiego Obszaru Metropolitalnego" wykonane przez zespół Zakładu Systemów Komunikacyjnych na Politechnice Krakowskiej pod kierownictwem pana dr hab. inż. Andrzeja Szaraty, prof. PK [131]. Badania te obejmowały m.in. zdefiniowanie potencjałów ruchotwórczych, określenie więzby ruchu, podział zadań przewozowych oraz rozkład ruchu w sieci. Wyniki badań wykorzystano do zdefiniowania pierwotnej macierzy podróży O-D oraz lokalizacji węzłów nadania i odbioru ruchu (tzw. centroid).

Drugim źródłem danych były wyniki badań przeprowadzonych przez ZIKIT w Krakowie w latach 2012-2013, które obejmowały bezpośrednie pomiary natężeń ruchu na wybranych skrzyżowaniach Krakowa. Pomiary ruchu zostały wykorzystane do określenia procentowego udziału poszczególnych kategorii pojazdów w potokach ruchu w wybranym obszarze sieci. Syntetyczne wyniki pomiarów dla 53 skrzyżowań przedstawia tabela 5-1, w której przedstawiono procentowy udział liczby pojazdów danej kategorii do łącznej sumy liczby pojazdów dla porannego szczytu komunikacyjnego.

Tabela 5-1 Procentowy udział kategorii pojazdów w ruchu drogowym dla centrum miasta Krakowa.


Godzina	Motocykle, skutery	Samochody osobowe	Mikrobusy	Lekkie samochody ciężarowe (dostawcze)	Samochody ciężarowe bez przyczep, samochody specjalne	Samochody ciężarowe z przyczepami, ciągniki z naczepami	Autobusy
06:30 - 06:45	124	23 131	1 067	1 831	497	100	697
06:45 - 07:00	156	27 859	1 098	2 203	498	104	700
07:00 - 07:15	187	29 741	1 209	2 143	465	125	746
07:15 - 07:30	262	34 761	1 056	2 039	408	132	704
07:30 - 07:45	333	36 175	1 122	2 030	480	117	754
07:45 - 08:00	374	36 477	1 189	2 121	493	102	851
08:00 - 08:15	287	35 422	1 111	2 314	529	102	848
08:15 - 08:30	260	34 967	1 084	2 355	555	90	1 012
08:30 - 08:45	310	35 207	1 163	2 448	577	161	1 017
08:45 - 09:00	320	34 441	1 127	2 447	541	132	915
09:00 - 09:15	326	33 154	1 186	2 539	554	105	889
09:15 - 09:30	310	31 670	1 094	2 513	554	122	872
Suma	3 249	393 005	13 506	26 983	6 151	1 392	10 005
% udział	0,72%	86,51%	2,97%	5,94%	1,35%	0,31%	2,20%

Źródło: opracowanie własne.

Wybór trzeciego źródła danych ruchowych był podyktowany specyfiką ruchu, jaka wynikała ze struktury potoków ruchu. Ponad 86% ruchu stanowią pojazdy osobowe. Kolejne niecałe 9% stanowią mikrobusy oraz samochody dostawcze, których charakterystyka poruszania się (tj. czas reakcji, parametry przyspieszania, zwalniania) mogą być utożsamione z pojazdami osobowymi. Udział pojazdów ciężarowych (obu typów) jest znikomy. Oznacza to, że w analizowanym obszarze sieci drogowej zdecydowana większość pojazdów to pojazdy osobowe. Dodatkowo biorąc pod uwagę obecne możliwości pomiarowe, jakie występują w infrastrukturze drogowej, założono, że wystarczającą informacją o przekrojowych natężeniach ruchu będą dane generowane przez indukcyjne czujniki pętlowe (potocznie zwane pętlami indukcyjnymi), umiejscowione na każdym pasie drogowym, każdego skrzyżowania ze sygnalizacją świetlną. Podczas przejazdu pojazdu nad pętlą indukcyjną następuje zmiana wartości impedancji czujnika, co jest rejestrowane, jako fakt przejazdu pojazdu (bez rozróżnienia na kategorie³⁵). Informacja ta może zostać wykorzystana do określenia, jaka wielkość potoków pojazdów w czasie porusza się wybranymi odcinkami sieci drogowej, z ewentualnym rozróżnieniem na pasy ruchu. Tego typu dane zostały wykorzystane do walidacji i kalibracji zbudowanego modelu. Pozyskane dane obejmowały informacje o dobowych natężeniach pojazdów


³⁵ W literaturze przedmiotu można odnaleźć badania przedstawiające możliwość pozyskiwania większej ilości informacji ze zmiany wartości impedancji, tj. struktura pojazdów. Jednak, dostępny system gromadzenia informacji z zamontowanych pętli indukcyjnych w Krakowie nie posiada takiej funkcjonalności.

dla całego tygodnia (od 1 grudnia do 7 grudnia 2014 roku) z interwałem jednogodzinnym dla wybranych detektorów. Po przeanalizowaniu użyteczności otrzymanych danych wybrano 56 pętli indukcyjnych, z których dane nie były obciążone błędami działania pętli. Lokalizacja detektorów została zaprezentowana na rysunku 5.4, a przykładowe dobowe natężenia ruchu oraz uśrednione dobowe natężenia ruchu dla dni roboczych przedstawiają rysunek 5.5 oraz rysunek 5.6.



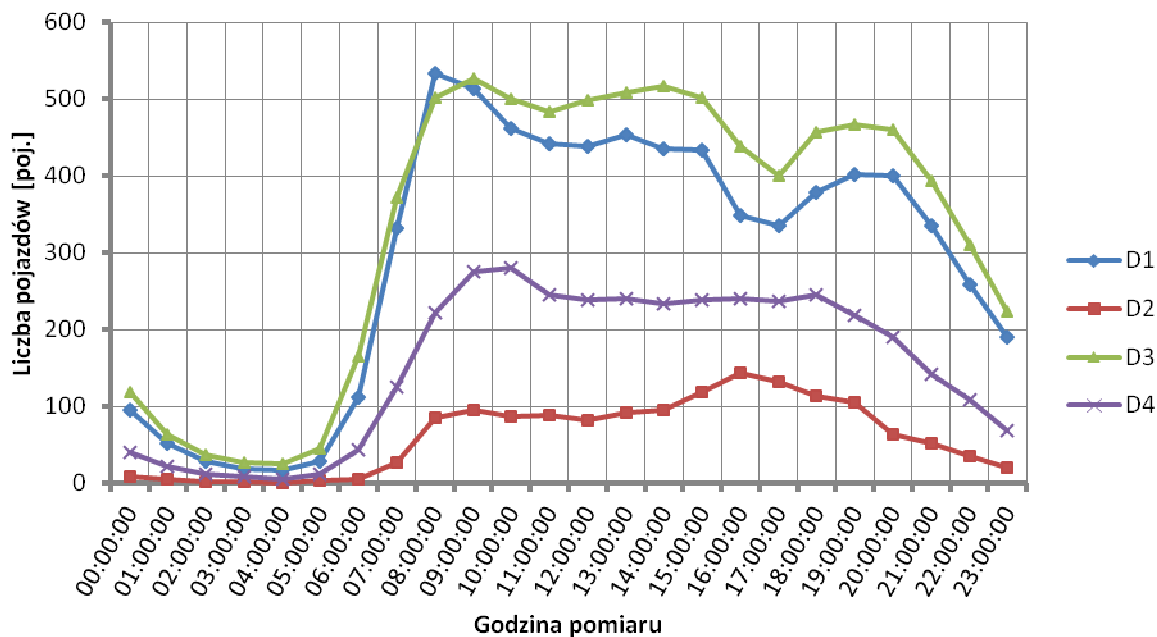
Rysunek 5.4 Lokalizacja pętli indukcyjnych, z których wykorzystano dane do symulacji.

Źródło: opracowanie własne.



Rysunek 5.5 Dobowe natężenia pojazdów na poszczególnych wlotach skrzyżowania ulic Słowackiego i Łobzowska w Krakowie dla dni roboczych. Wlot D1 - al. Słowackiego północ; wlot D2 - ul. Łobzowska wschód; wlot D3 - al. Słowackiego południe; wlot D4 - ul. Łobzowska zachód.

Źródło: opracowanie własne.



Rysunek 5.6 Średnie dobowe natężenia pojazdów na poszczególnych wlotach skrzyżowania ulic Słowackiego i Łobzowska w Krakowie dla dni roboczych. Wlot D1 - al. Słowackiego północ; wlot D2 - ul. Łobzowska wschód; wlot D3 - al. Słowackiego południe; wlot D4 - ul. Łobzowska zachód.

Źródło: opracowanie własne.

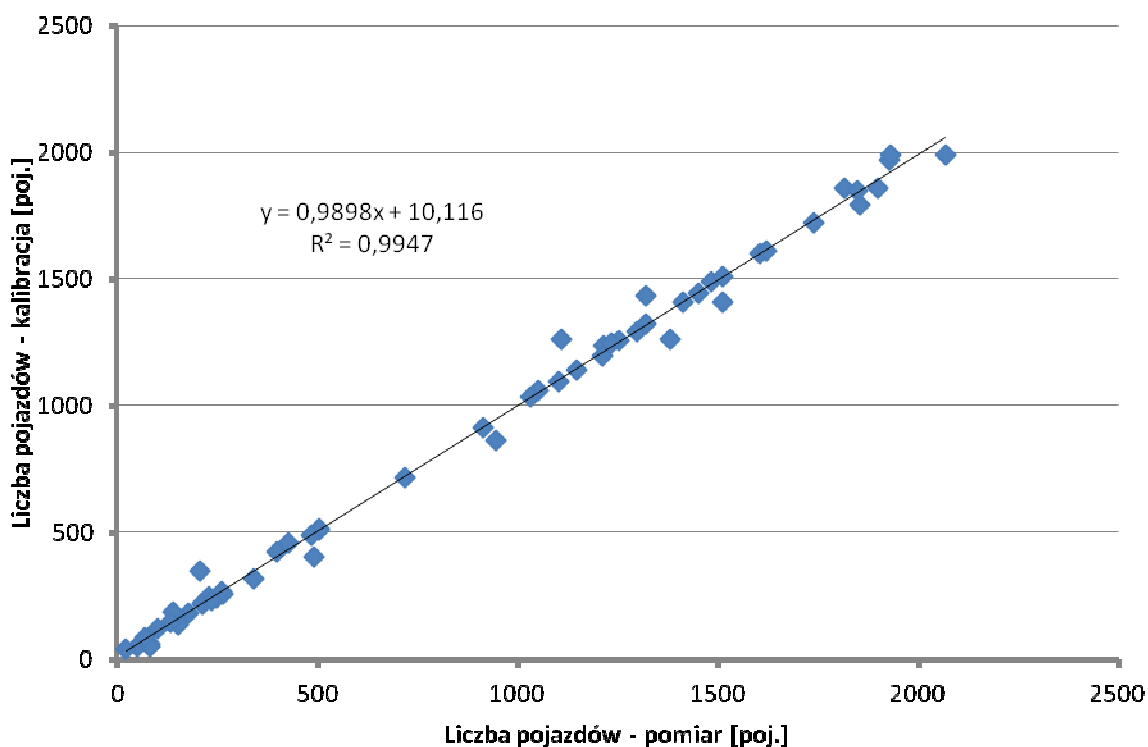
Przedstawione powyżej wykresy potwierdzają (dość oczywiste) występowanie dobrze znanego zjawiska - szczytu komunikacyjnego. W typowych warunkach drogowych w Krakowie występują dwa szczyty komunikacyjne: poranny oraz popołudniowy. Szczyt poranny charakteryzuje się zwiększoną intensywnością niż szczyt popołudniowy, ale trwa krócej w ciągu dnia. Największa liczba zarejestrowanych pojazdów w ciągu doby występuje w godzinach 6:00 do 21:00 i taki okres został przyjęty do dalszych etapów modelowania. Analizy ograniczono do zmienności warunków ruchowych dla jednego dnia - czwartek 04.12.2014 roku.

Referencyjny zbiór najkrótszych ścieżek

Głównym założeniem symulatorów ruchu drogowego jest prowadzenie pojazdów pomiędzy dwoma punktami sieci drogowej w oparciu o zbiór ścieżek. Jeśli dane te nie są dostępne, symulator najczęściej tworzy zbiór ścieżek przez generator najkrótszych ścieżek utworzonych na bazie stochastycznych założeń w warunkach czasu przejazdu na odcinkach sieci. Pozyskanie informacji, w jaki sposób każdy uczestnik ruchu wybiera swoją trasę w celu przejazdu z punktu A do punktu B w sieci jest podstawowym problemem teorii modelowania. Z technologicznego punktu widzenia, pozyskanie informacji o ścieżkach nie stanowi problemu. Jednakże z praktycznego punktu widzenia jest dość problematyczne.

Jako referencyjną bazę najkrótszych ścieżek przyjęto zbiór ścieżek uzyskany w procesie kalibracji macierzy podróży O-D z rzeczywistymi danymi z pomiarów pętli indukcyjnych (ang. Macro Matrix Adjustment). Proces kalibracji macierzy O-D jest pewnego rodzaju odwróconą procedurą rozkładu ruchu w sieci, w którym celem jest wyznaczenie wielkości natężeń na odcinkach sieci na podstawie ilości podróży macierzy O-D i/lub modelu wyboru ścieżek. Celem procesu kalibracji macierzy O-D jest obliczenie wartości w macierzy podróży O-

D na podstawie punktowych pomiarów natężeń pojazdów [10]. W programie Aimsun procedura kalibracji macierzy O-D polega na iteracyjnym poszukiwaniu takiego rozkładu ruchu w sieci, którego błąd najmniejszych kwadratów w odniesieniu do danych z detektorów był najmniejszy. Z uwagi, że tak sformułowane zadanie jest problemem optymalizacji nieliniowej, do rozwiązania go wykorzystana jest heurystyka dwupoziomowej optymalizacji opartej o prace [10, 40, 58]. Rozkład ruchu w sieci, który jest etapem procesu kalibracji, jest oparty o metodę liniowej aproksymacji Frank'a i Wolfe'a. W wykonanych symulacjach zbieżność algorytmu ustawiono poprzez: osiągnięcia 50 iteracji i/lub uzyskanie względnej różnicy pomiędzy kolejnymi iteracjami równą 0,1. Dla każdej godziny z analizowanego okresu wykonano proces kalibracji, w wyniku, którego otrzymano skalibrowane wartości w macierzy O-D oraz referencyjny zbiór ścieżek (wygenerowany do pliku). Dane te wykorzystano do przeprowadzenia właściwych symulacji mikroskopowych. Przykładowy wynik procesu kalibracji przedstawiono na rysunku 5.7, gdzie zaprezentowano porównanie pomiarów rzeczywistych z natężeniami z symulacji. Współczynnik determinacji R^2 we wszystkich przypadkach nie był mniejszy niż 98%.



Rysunek 5.7 Porównanie wyników kalibracji macierzy O-D z rzeczywistymi pomiarami dla wybranej godziny.

Źródło: opracowanie własne.

Czas reakcji kierowców

W modelowaniu mikroskopowym ruchu drogowego jedną z podstawowych informacji, która ma istotny wpływ na przebieg i wynik symulacji, są parametry opisujące zachowania kierowców/pojazdów. W ujęciu mikroskopowym zachowanie się każdego z pojazdów (np. prędkość poruszania się) jest określana w oparciu o warunki wokół pojazdu tj. sposób poruszania się pojazdu poprzedzającego (model jazdy za liderem [60]), czy pojazdu sąsiadującego, stanu sygnalizacji świetlnej, informacji przekazywanych przez znaki drogowe lub występują-

ce zatory drogowe. W założeniach symulacji mikroskopowej programu Aimsun, poruszanie się pojazdu jest obliczane zgodnie z modelem podążania za liderem oraz modelem zmiany pasa opracowanym przez P.G. Gipps [9]. W modelu podążania za liderem zakłada się, że prędkość, z jaką porusza się pojazd w i-tym kroku symulacji jest określana przez: parametr chęci przyspieszania do określonej prędkości, spowolnienie wynikające z warunków lokalnych pojazdu (ograniczenie prędkości, warunki pogodowe) oraz czas reakcji kierowcy [9].

Obecna wersja symulatora umożliwia wyszczególnienie czterech typów czasów reakcji kierowców [9]:

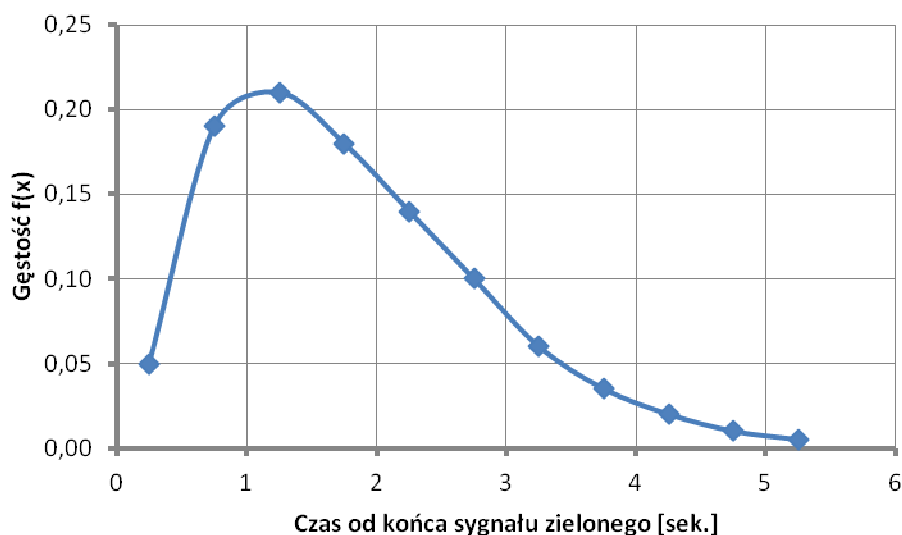
1. Czas reakcji w ruchu - jest to czas reakcji, jaki potrzebuje kierowca, aby dostosować swoją prędkość na podstawie zachowań pojazdu poprzedzającego,
2. Czas reakcji podczas postoju - jest to czas, jaki potrzebuje kierowca, aby rozpocząć przyspieszanie z postoju (reakcja na start pojazdu poprzedzającego),
3. Czas reakcji na sygnalizację świetlną - jest to czas reakcji na sygnał zielony sygnalizacji świetlnej na skrzyżowaniu, jaki potrzebuje kierowca, aby rozpocząć poruszania się,
4. Reakcja kierowców na sygnał żółty - określa zachowanie się kierowców podczas zmiany sygnału światła zielonego na żółty.

Pierwszy parametr jest wykorzystywany we wspomnianym modelu podążania pojazdu Gipps'a. Oznacza on, jak szybko kierowca dostosowuje swoją prędkość poruszania się do prędkości poprzedzającego go pojazdu. Jak wskazano to w pracy [98] czas reakcji w ruchu jest wypadkową dwóch parametrów: czasu reakcji przyspieszania/zwalniania (ang. Acceleration or deceleration reaction time) - dalej czas RP/Z oraz czasu reakcji hamowania (ang. Break-reaction time) - dalej czas RH. Czas RP/Z jest to różnica pomiędzy momentem otrzymania sygnału świetlnego przez kierowcę w celu dopasowania swojej prędkości, a momentem rozpoczęcia dopasowywania swojej prędkości. Analogicznie można zdefiniować czas RH - jest to różnica pomiędzy momentem otrzymania sygnału światła stopu poprzedzającego pojazdu, a momentem reakcji kierowcy na ten sygnał. W pracy [75] czas ten określono, jako czas reakcji psychomotorycznej podczas hamowania, wyznaczany, jako czas od momentu pojawienia się przeszkody do początku pojawienia się siły na pedale hamulca. Dodatkowo czas reakcji hamowania można przyjmować różne wartości w zależności od sytuacji, np. czy kierowca reaguje w ruchu stacjonarnym (warunki zatłoczenia), normalnym, czy w sytuacjach awaryjnych.

Jak wynika z wykonanego przeglądu badań krajowych, nie ma bezpośrednich badań nad określeniem wartości czasu reakcji przyspieszania/zwalniania. Do badań, które w sposób pośredni analizują wskazane zjawisko, to badania przedstawione w pracach [37, 106], gdzie wykonano pomiar odstępów pomiędzy kolejnymi pojazdami przejeżdżającymi linię zatrzymania na drogach miejskich i zamiejskich w ciągu trwania fazy światła zielonego. Wielkość zmierzzonego odstępu w postaci interwału czasowego może w sposób uwikłany opisywać czas RP/Z. Z badań tych wynika, że w zależności od warunków pogodowych kierujący pierwszymi pojazdami wymuszają określone zachowania na pozostałych kierowcach z kolejki pojazdów [106]. Średni czas odstępu pomiędzy pojazdami na drogach miejskich wyniósł 1,87 [sek.], a odchylenie standardowe wyniosło 0,18 [sek.]. Ciekawym zjawiskiem, jakie zostało zaobserwowane w przytoczonych badaniach, to stopniowe zmniejszanie się odległości pomiędzy pojazdami w końcowej fazie sygnału zielonego. Jednakże odstęp pomiędzy pojazdami

w postaci czasu nie jest dokładnym odzwierciedleniem rozważanego parametru, ponieważ uwzględnia on również charakterystykę techniczną pojazdu oraz wpływ topografii sieci drogowej. Drugim elementem czasu reakcji kierowcy w ruchu jest czas reakcji na hamowanie - RH. W przypadku tego parametru zostały wykonane dość kompleksowe badania, które zostały zaprezentowane w pracy [75]. Analizy wykonano w symulatorze jazdy samochodem w rzeczywistej kabinie samochodowej z wykorzystaniem specjalistycznego oprogramowania oraz w badaniach poligonowych. Dla próby 107 osób, w wieku od 25 lat do powyżej 46 lat otrzymano średni czas reakcji na hamowanie z przedziału 0,42-0,92 sekundy, a odchylenie standardowe wyniosło 0,05 do 0,29 sekundy.

Reasumując, na podstawie przytoczonych badań oraz wielokrotnie wykonanych symulacji mikroskopowych w procesie kalibracji, przyjęto, że czas reakcji w ruchu będzie przyjmować wartości z zakresu: wartość oczekiwana 0,9 [sek.], a odchylenie standardowe równe 0,4 [sek.]. Natomiast czas reakcji podczas postoju opisano przez wartość oczekiwaną równą 1,27 [sek.] i wartość odchylenia standardowego równego 0,58 [sek.]. Trzeci czas reakcji został wprowadzony bezpośrednio zgodnie z wynikami uzyskanymi w badaniach [106]. Założenia przedstawia rysunek 5.8.



Rysunek 5.8 Funkcja gęstości czasu reakcji kierowcy na sygnał zielony.

Źródło: opracowanie własne na podstawie [37, 106].

Ostatni rozważany parametr - czas reakcji na sygnał żółty, został zbadany na próbie kierowców w Krakowie w stanach nasycenia ruchem (np. szczyty komunikacyjne). Zgodnie z wynikami zaobserwowano, że od 8% do 25% kierowców przejeżdża na sygnale żółtym i sygnale czerwonym, co jest niezgodne z prawem. Informacja ta została wykorzystana do określenia procentowego udziału kierowców, którzy traktują sygnał żółty, jako sygnał zielony.

Na podstawie powyższych założeń przeprowadzono dalszy proces kalibracji modelu, gdzie analizowano kolejne parametry takie jak: sposób wyboru najkrótszej ścieżki; długość cyklu, po którym aktualizowane są najkrótsze ścieżki; opcje modelu poruszania za liderem oraz modelu zmiany pasa ruchu. Na podstawie serii wykonanych symulacji uzyskano wyniki modelu, którego oceny dokonano na podstawie wskaźnika statystycznego GEH.

Walidacja i kalibracja modelu

Charakterystykę ruchu drogowego analizowanej sieci drogowej uzyskano poprzez wykonanie szeregu mikroskopowych symulacji w komputerowym symulatorze ruchu drogowego. Ważnym etapem modelowania jest weryfikacja uzyskanych wyników z modelu z danymi pochodzącymi z rzeczywistości. Na etap ten składają się dwa procesy - walidacja i kalibracja modelu. Proces walidacji jest wykonywany w celu określenia sensowności i użyteczności modelu i polega na ocenie założeń i sposobów reprezentacji problemu oraz porównaniu uzyskanych wyników z danymi pochodzącymi z analizowanej sieci drogowej. Walidacja występuje, więc na początku modelowania, ale również w trakcie tego procesu. Kalibracji polega na dążeniu do uzyskania wystarczającego poziomu wierności odwzorowania rzeczywistości w modelu symulacyjnym, poprzez konfigurację i modyfikację parametrów programu komputerowego [35]. Wystarczający poziom wierności modelu może być oceniany przez różne charakterystyki ruchu lub wskaźniki statystyczne (np. współczynnik determinacji, współczynnik GEH lub statystyka Theil'a). W zaawansowanych formach kalibracja może przybierać formę procesu optymalizacyjnego, gdzie zmiennymi są wartości parametrów programu, a celem takiej optymalizacji jest otrzymanie najmniejszej różnicy wyników modelu z danymi z rzeczywistości [41].

W rozpatrywanym przypadku proces walidacji i kalibracji modelu został przeprowadzony metodą sukcesywnego modyfikowania parametrów programu w celu osiągnięcia zgodności modelu wyznaczony przez wskaźnik GEH. Wskaźnik GEH został zaproponowany w podręczniku do projektowania dróg mostów wydanym przez The Highways Agency, Scottish Government, Welsh Assembly Government Llywodraeth Cynulliad Cymru oraz the Department for Regional Development Northern Ireland [47]. Parametr ten można sformułować następująco:

$$GEH = \sqrt{\frac{2(M-C)^2}{(M+C)}} \quad (5.1)$$

gdzie:

M - natężenie ruchu w przekroju drogi uzyskane z modelu [poj./h],

C - natężenie ruchu w przekroju drogi uzyskane z pomiaru [poj./h],

Model można uznać za skalibrowany, jeśli wartość jego jest mniejsza lub równa 5 dla co najmniej 85% łącznej liczby analizowanych przekroi pomiarowych. Jeśli wartość GEH przyjmuje wartości z zakresu (5,10], to oznacza to, że założenia modelu powinny być zweryfikowane. Z kolei, jeśli $GEH > 10$, dany punkt pomiarowy należy odrzucić lub zweryfikować.

Wyniki symulacji

Tabela 5-2 przedstawia dane z pomiaru rzeczywistego, kolejna tabela przedstawia informacje o natężeniach pojazdów uzyskanych z symulacji (tabela 5-3), a tabela 5-4 przedstawia uzyskane wskaźniki GEH dla każdej godziny. Wskaźniki te zostały obliczone osobno dla każdego detektora w zależności od czasu, dla każdej godziny w zależności od detektora oraz całościowo. Przyjęto, że analizowanym dniem był 4 grudnia 2014 roku (środa). Pomimo, że

dla niektórych przypadków w ujęciu na poszczególne detektory lub poszczególne godziny, wskaźnik GEH jest mniejszy niż wymagany, w ujęciu całej jest on mniejszy niż 5 dla 85,36% analizowanych punktów poprzecznego pomiaru, co świadczy o tym, że model jest statystycznie zbieżny z rzeczywistym obiektem.

Tabela 5-2 Godzinowa liczba pojazdów w wybranych punktach dla centrum Krakowa dla godzin 6:00 - 21:00 w dniu roboczym czwartek 04.12.2014r. - pomiar rzeczywisty.

Lp.	Nazwa detektora	Liczba pojazdów [poj./h]														SUMA	
		6:00-7:00	7:00-8:00	8:00-9:00	9:00-10:00	10:00-11:00	11:00-12:00	12:00-13:00	13:00-14:00	14:00-15:00	15:00-16:00	16:00-17:00	17:00-18:00	18:00-19:00	19:00-20:00		20:00-21:00
1	101_D2	1 382	2 243	2 154	1 902	1 726	1 801	1 768	1 844	1 789	1 564	1 440	1 487	1 541	1 617	1 338	25 596
2	101_D4	1 211	1 613	1 759	1 749	1 681	1 685	1 661	1 658	1 674	1 615	1 593	1 610	1 511	1 626	1 253	23 899
3	102_D1	503	580	479	504	465	498	508	570	466	401	400	508	528	611	481	7 502
4	102_D2	1 109	1 912	1 870	1 634	1 406	1 568	1 539	1 664	1 606	1 558	1 416	1 428	1 416	1 439	1 050	22 615
5	102_D3	177	332	335	368	285	381	427	415	443	501	503	517	454	364	265	5 767
6	102_D4	1 050	1 424	1 507	1 461	1 374	1 425	1 382	1 390	1 381	1 294	1 299	1 403	1 297	1 379	1 125	20 191
7	103_D2	83	181	237	237	248	271	262	293	325	293	341	327	269	229	175	3 771
8	103_D3	1 235	1 509	1 650	1 602	1 437	1 668	1 591	1 533	1 460	1 353	1 272	1 445	1 410	1 495	1 321	21 981
9	104_D1	1 299	2 132	2 056	1 860	1 783	1 761	1 762	1 882	1 815	1 590	1 522	1 584	1 627	1 763	1 319	25 755
10	104_D2	49	178	196	164	163	175	183	195	249	275	307	225	206	138	109	2 812
11	104_D3	1 102	1 473	1 547	1 541	1 454	1 549	1 490	1 451	1 420	1 254	1 207	1 360	1 328	1 493	1 190	20 859
12	104_D4	247	464	581	553	515	524	508	447	474	528	576	525	488	408	319	7 157
13	105_D1	1 214	1 922	1 894	1 784	1 694	1 651	1 672	1 748	1 726	1 470	1 371	1 442	1 530	1 584	1 250	23 952
14	105_D2	83	101	103	120	110	109	115	102	96	107	98	77	86	90	88	1 485
15	105_D3	1 252	1 858	1 985	1 937	1 862	1 882	1 846	1 949	1 895	1 740	1 557	1 715	1 741	1 813	1 391	26 423
16	106_D1	1 146	1 798	1 862	1 655	1 584	1 568	1 529	1 658	1 600	1 461	1 396	1 403	1 468	1 550	1 196	22 874
17	106_D3	1 606	2 106	2 179	2 110	1 976	2 038	2 045	2 127	2 128	2 037	1 764	1 948	2 007	2 046	1 529	29 646
18	107_D1	1 319	2 112	2 223	2 019	1 952	1 962	1 944	2 062	2 067	1 965	1 842	1 874	1 960	1 911	1 487	28 699
19	107_D3	1 854	2 269	2 288	2 281	2 152	2 211	2 146	2 281	2 263	2 236	1 920	2 160	2 245	2 084	1 656	32 046
20	108_D1	1 511	2 371	2 544	2 248	2 151	2 098	2 165	2 272	2 252	2 148	2 120	2 089	2 129	2 308	1 761	32 167
21	108_D3	1 817	2 173	2 169	2 128	2 043	2 025	1 997	2 117	1 964	1 846	1 570	1 759	1 991	1 935	1 565	29 099
22	108_D4	23	53	66	63	74	69	100	108	133	153	119	74	86	76	60	1 257
23	109_D2	212	521	621	535	524	561	568	576	609	670	634	699	575	486	382	8 173
24	109_D3	1 931	2 230	2 175	2 122	1 983	2 050	2 078	2 102	2 022	1 908	1 577	1 676	1 996	1 958	1 589	29 397
25	109_D4	235	568	585	605	572	552	526	521	499	539	520	517	418	446	290	7 393
26	110_D1	1 412	2 263	2 598	2 353	2 403	2 417	2 498	2 480	2 626	2 657	2 645	2 550	2 480	2 574	2 059	36 015
27	110_D2	229	659	788	713	796	721	732	768	838	786	771	789	776	595	474	10 435
28	110_D3	1 739	1 849	1 659	1 600	1 527	1 500	1 522	1 522	1 643	1 551	1 284	1 419	1 604	1 740	1 357	23 516

Optymalizacja typu "robust" tras przewozu ładunków na obszarach miejskich- D. Kubek

29	110_D4	264	625	607	624	621	608	588	629	572	634	640	671	622	444	308	8 457
30	131_D1	1 928	2 720	2 610	2 273	2 058	2 015	1 971	1 884	1 911	1 698	1 486	1 704	1 714	1 687	1 289	28 948
31	131_D4	212	430	413	389	336	375	383	405	394	353	344	324	330	246	185	5 119
32	132_D1	1 900	2 408	2 317	2 110	1 923	1 835	1 771	1 716	1 750	1 533	1 364	1 560	1 607	1 587	1 203	26 584
33	191_D1	1 482	2 277	2 382	2 278	2 208	2 294	2 228	2 378	2 371	2 253	2 149	2 218	2 212	2 387	1 930	33 047
34	191_D3	2 068	2 412	2 378	2 395	2 282	2 331	2 394	2 415	2 320	2 057	1 786	1 875	2 281	2 208	1 794	32 996
35	191_D4	103	196	200	193	180	196	224	210	210	258	222	190	159	144	107	2 792
36	321_D1	1 511	1 592	1 800	1 728	1 863	1 536	1 572	1 415	1 769	1 535	1 452	1 555	1 491	1 512	1 131	23 462
37	321_D2	1 031	1 371	1 387	1 227	1 196	1 227	1 280	1 168	1 367	1 436	1 283	1 284	1 039	951	727	17 974
38	321_D3	1 847	1 660	1 864	1 780	1 515	1 727	1 587	1 668	1 596	1 787	1 788	1 791	1 307	1 139	776	23 832
39	321_D4	915	1 243	1 155	927	1 008	951	1 176	1 080	1 060	1 175	1 143	1 156	980	788	655	15 412
40	323_D1	68	75	115	112	76	148	80	88	148	147	104	128	96	51	40	1 476
41	324_D4	206	832	979	968	807	863	891	799	919	859	891	867	859	842	540	12 122
42	325_D2	719	1 020	1 140	1 112	1 147	1 196	1 076	1 060	1 323	972	1 095	1 115	1 040	1 059	763	15 837
43	325_D4	340	504	435	475	488	423	487	440	372	467	419	444	432	464	340	6 530
44	326_D2	484	676	663	583	708	580	664	491	560	547	571	635	580	504	404	8 650
45	326_D3	260	408	392	299	340	339	271	380	244	383	324	335	332	312	235	4 854
46	326_D4	947	1 063	1 011	940	872	880	856	887	935	1 048	951	887	744	655	448	13 124
47	327_D1	132	303	267	299	327	260	360	323	307	300	272	279	275	232	172	4 108
48	327_D2	492	747	803	868	950	1 046	1 028	1 095	1 114	915	855	854	784	851	651	13 053
49	327_D3	139	188	260	219	252	255	260	352	259	268	243	183	212	243	163	3 496
50	327_D4	1 320	1 848	1 723	1 508	1 316	1 267	1 315	1 355	1 551	1 299	1 458	1 424	1 215	1 107	583	20 289
51	328_D1	151	739	355	183	172	179	155	359	351	295	268	271	215	163	112	3 968
52	328_D2	427	687	764	844	819	747	828	935	812	828	779	748	740	783	643	11 384
53	328_D4	1 622	2 160	2 075	1 580	1 379	1 387	1 335	1 375	1 674	1 387	1 723	1 620	1 344	1 052	619	22 332
54	430_D1	504	1 004	963	800	911	912	975	936	939	847	864	912	911	872	535	12 885
55	430_D2	399	675	800	812	735	843	856	940	867	892	912	779	796	851	639	11 796
56	430_D4	1 451	1 643	1 619	1 236	1 219	1 136	1 372	1 268	1 224	1 176	1 396	1 347	1 247	1 015	704	19 053
SUMA		49 952	70 400	71 587	66 610	63 648	64 276	64 547	65 786	66 382	62 849	59 846	61 766	60 731	59 907	45 775	934 062

Źródło: opracowanie własne.

Tabela 5-3 Godzinowa liczba pojazdów w wybranych punktach dla centrum Krakowa dla godzin 6:00 - 21:00 w dniu roboczym czwartek 04.12.2014r. - wyniki symulacji komputerowych.

Lp.	Nazwa detektora	Liczba pojazdów [poj./h]															SUMA
		6:00-7:00	7:00-8:00	8:00-9:00	9:00-10:00	10:00-11:00	11:00-12:00	12:00-13:00	13:00-14:00	14:00-15:00	15:00-16:00	16:00-17:00	17:00-18:00	18:00-19:00	19:00-20:00	20:00-21:00	
1	101_D2	1 226	1 921	1 874	1 746	1 593	1 692	1 597	1 701	1 692	1 446	1 319	1 362	1 369	1 448	1 171	23 157
2	101_D4	1 136	1 404	1 538	1 578	1 580	1 536	1 499	1 432	1 480	1 452	1 433	1 393	1 377	1 483	1 242	21 563
3	102_D1	525	499	442	456	467	363	381	471	369	374	304	354	434	558	438	6 435
4	102_D2	1 222	1 931	1 905	1 766	1 597	1 713	1 622	1 713	1 712	1 465	1 375	1 414	1 438	1 499	1 177	23 549
5	102_D3	197	384	415	443	346	498	492	481	522	531	510	512	450	422	276	6 479
6	102_D4	932	1 217	1 232	1 269	1 198	1 231	1 224	1 173	1 162	1 063	1 150	1 156	1 180	1 173	1 093	17 453
7	103_D2	118	203	206	204	207	265	264	282	266	266	265	227	254	272	156	3 455
8	103_D3	1 229	1 681	1 643	1 679	1 585	1 703	1 707	1 645	1 592	1 436	1 415	1 531	1 587	1 610	1 440	23 483
9	104_D1	1 399	2 177	2 112	2 014	2 005	1 987	1 887	1 975	1 921	1 746	1 737	1 709	1 722	1 888	1 347	27 626
10	104_D2	72	175	212	198	236	242	226	223	242	256	215	188	231	206	119	3 041
11	104_D3	1 146	1 544	1 606	1 631	1 655	1 730	1 622	1 690	1 608	1 365	1 294	1 438	1 458	1 728	1 325	22 840
12	104_D4	253	384	276	368	377	389	399	334	351	454	490	421	436	328	291	5 551
13	105_D1	1 163	1 691	1 581	1 615	1 633	1 609	1 545	1 535	1 544	1 326	1 263	1 299	1 452	1 517	1 136	21 909
14	105_D2	99	140	108	211	249	275	152	136	194	171	117	120	123	265	123	2 483
15	105_D3	1 167	1 821	1 840	1 861	1 830	1 816	1 819	1 879	1 815	1 637	1 501	1 636	1 697	1 748	1 411	25 478
16	106_D1	1 023	1 606	1 424	1 583	1 559	1 486	1 476	1 344	1 458	1 341	1 295	1 277	1 421	1 407	1 079	20 779
17	106_D3	1 530	2 083	2 150	1 988	1 888	1 963	1 967	2 002	2 053	1 875	1 724	1 860	1 881	1 952	1 499	28 415
18	107_D1	1 298	1 910	1 895	1 852	1 850	1 692	1 798	1 614	1 775	1 714	1 756	1 622	1 834	1 757	1 459	25 826
19	107_D3	1 700	2 097	2 202	2 042	1 960	2 011	1 993	2 015	2 127	1 746	1 643	1 795	1 966	1 871	1 535	28 703
20	108_D1	1 312	2 272	2 153	2 135	1 993	1 668	1 867	1 754	1 900	1 796	1 908	1 724	1 810	2 182	1 712	28 186
21	108_D3	1 871	2 240	2 206	2 191	2 164	2 154	2 170	2 227	2 176	1 858	1 763	1 892	2 104	2 020	1 679	30 715
22	108_D4	34	111	46	42	59	69	69	102	109	139	117	63	79	105	65	1 209
23	109_D2	258	520	578	536	566	564	576	564	609	606	562	587	603	473	410	8 012
24	109_D3	2 012	2 277	2 263	2 278	2 190	2 201	2 333	2 184	2 206	1 960	1 902	1 955	2 334	2 113	1 871	32 079
25	109_D4	236	568	587	618	584	540	500	503	522	553	546	536	422	520	287	7 522
26	110_D1	1 381	2 033	2 142	2 111	2 147	2 031	2 177	2 010	2 287	2 215	2 324	2 347	2 287	2 268	1 919	31 679
27	110_D2	287	695	837	776	875	791	822	810	875	766	811	817	919	631	545	11 257
28	110_D3	1 737	1 869	1 589	1 671	1 551	1 595	1 657	1 600	1 598	1 455	1 375	1 452	1 692	1 681	1 410	23 932
29	110_D4	264	595	504	596	634	625	587	569	487	520	565	554	600	432	288	7 820

Optymalizacja typu "robust" tras przewozu ładunków na obszarach miejskich- D. Kubek

30	131_D1	1 961	2 730	2 645	2 406	2 127	1 938	1 971	1 808	1 888	1 635	1 410	1 546	1 603	1 661	1 270	28 599
31	131_D4	220	428	367	378	313	374	339	337	374	292	306	301	325	249	211	4 814
32	132_D1	1 864	2 230	2 197	2 066	1 980	1 831	1 891	1 772	1 823	1 643	1 413	1 550	1 604	1 659	1 267	26 790
33	191_D1	1 450	2 103	2 037	2 127	2 015	1 918	2 057	1 839	2 194	2 022	2 048	2 149	2 198	2 181	1 898	30 236
34	191_D3	1 996	2 294	2 259	2 285	2 176	2 190	2 344	2 197	2 200	1 965	1 904	1 979	2 330	2 160	1 869	32 148
35	191_D4	129	214	261	199	183	219	230	203	215	251	221	211	185	175	154	3 050
36	321_D1	1 738	1 598	1 542	1 784	1 810	1 618	1 392	1 491	1 683	1 557	1 590	1 650	1 601	1 623	1 374	24 051
37	321_D2	986	1 246	1 264	1 157	1 182	1 260	1 227	1 135	1 289	1 397	1 295	1 277	1 051	977	742	17 485
38	321_D3	1 911	1 388	1 353	1 742	1 429	1 670	1 172	1 246	1 617	1 373	1 766	1 680	1 317	1 171	784	21 619
39	321_D4	992	1 341	1 261	1 076	1 252	1 097	1 364	1 278	1 292	1 294	1 244	1 336	1 100	939	684	17 550
40	323_D1	97	113	158	127	100	148	136	111	185	156	116	139	114	80	57	1 837
41	324_D4	447	865	891	967	877	891	861	714	825	882	908	865	891	864	481	12 229
42	325_D2	691	828	946	1 000	1 055	1 152	930	988	1 194	863	1 035	1 070	972	1 045	756	14 525
43	325_D4	521	473	440	353	398	338	359	404	292	404	440	352	356	334	294	5 758
44	326_D2	481	568	596	499	639	572	587	507	541	495	612	615	586	495	431	8 224
45	326_D3	240	455	399	331	375	356	276	363	257	378	374	336	332	352	249	5 073
46	326_D4	912	1 120	1 077	1 065	893	916	902	805	971	1 013	1 071	991	853	729	421	13 739
47	327_D1	141	369	323	353	361	238	347	313	316	282	295	274	277	234	153	4 276
48	327_D2	408	526	738	807	766	829	866	939	834	765	742	788	745	734	620	11 107
49	327_D3	204	181	254	205	250	253	255	340	235	262	221	164	202	266	157	3 449
50	327_D4	1 359	1 759	1 827	1 581	1 284	1 315	1 253	1 321	1 588	1 282	1 605	1 542	1 215	1 107	514	20 552
51	328_D1	121	515	255	188	152	153	126	217	212	259	240	215	181	176	103	3 113
52	328_D2	440	517	831	852	791	840	880	960	900	778	810	834	788	807	644	11 672
53	328_D4	1 542	2 070	1 965	1 580	1 332	1 393	1 296	1 332	1 640	1 319	1 716	1 648	1 308	1 095	525	21 761
54	430_D1	524	1 004	897	802	899	819	938	785	928	846	873	1 005	913	881	590	12 704
55	430_D2	431	827	807	874	745	830	868	923	869	829	862	791	866	886	681	12 089
56	430_D4	1 379	1 674	1 598	1 255	1 182	1 175	1 352	1 256	1 192	1 172	1 332	1 328	1 276	1 145	784	19 100
SUMA		50 012	67 484	66 754	65 517	63 144	62 772	62 647	61 552	64 206	58 946	59 128	59 877	60 349	59 582	46 216	908 186

Źródło: opracowanie własne.

Tabela 5-4 Wskaźniki GEH dla symulacji mikroskopowych dla poszczególnych detektorów i godzin.

Nazwa detektora	Godzina															GEH <=5	
	7:00	8:00	9:00	10:00	11:00	12:00	13:00	14:00	15:00	16:00	17:00	18:00	19:00	20:00	21:00	ilość	% udział
101_D2	4,32	7,06	6,24	3,65	3,26	2,61	4,17	3,40	2,33	3,04	3,26	3,31	4,51	4,32	4,71	13	86,7%
101_D4	2,19	5,38	5,44	4,19	2,50	3,71	4,08	5,75	4,89	4,16	4,11	5,60	3,53	3,63	0,31	11	73,3%
102_D1	0,97	3,49	1,72	2,19	0,09	6,51	6,02	4,34	4,75	1,37	5,12	7,42	4,29	2,19	2,01	11	73,3%
102_D2	3,31	0,43	0,81	3,20	4,93	3,58	2,09	1,19	2,60	2,39	1,10	0,37	0,58	1,57	3,81	15	100,0%
102_D3	1,46	2,75	4,13	3,72	3,43	5,58	3,03	3,12	3,60	1,32	0,31	0,22	0,19	2,93	0,67	14	93,3%
102_D4	3,75	5,70	7,43	5,20	4,91	5,32	4,38	6,06	6,14	6,73	4,26	6,91	3,32	5,77	0,96	6	40,0%
103_D2	3,49	1,59	2,08	2,22	2,72	0,37	0,12	0,65	3,43	1,62	4,37	6,01	0,93	2,72	1,48	14	93,3%
103_D3	0,17	4,31	0,17	1,90	3,81	0,85	2,86	2,81	3,38	2,22	3,90	2,23	4,57	2,92	3,20	15	100,0%
104_D1	2,72	0,97	1,23	3,50	5,10	5,22	2,93	2,12	2,45	3,82	5,33	3,08	2,32	2,93	0,77	12	80,0%
104_D2	2,96	0,23	1,12	2,53	5,17	4,64	3,01	1,94	0,45	1,17	5,69	2,57	1,69	5,18	0,94	12	80,0%
104_D3	1,31	1,83	1,49	2,26	5,10	4,47	3,35	6,03	4,83	3,07	2,46	2,09	3,48	5,86	3,81	12	80,0%
104_D4	0,38	3,89	14,73	8,62	6,53	6,32	5,12	5,72	6,06	3,34	3,73	4,78	2,42	4,17	1,60	8	53,3%
105_D1	1,48	5,43	7,51	4,10	1,50	1,04	3,17	5,26	4,50	3,85	2,98	3,86	2,02	1,70	3,30	12	80,0%
105_D2	1,68	3,55	0,49	7,07	10,37	11,98	3,20	3,12	8,14	5,43	1,83	4,33	3,62	13,14	3,41	9	60,0%
105_D3	2,44	0,86	3,32	1,74	0,74	1,53	0,63	1,60	1,86	2,51	1,43	1,93	1,06	1,54	0,53	15	100,0%
106_D1	3,73	4,65	10,81	1,79	0,63	2,10	1,37	8,10	3,63	3,21	2,75	3,44	1,24	3,72	3,47	13	86,7%
106_D3	1,92	0,50	0,62	2,70	2,00	1,68	1,74	2,75	1,64	3,66	0,96	2,02	2,86	2,10	0,77	15	100,0%
107_D1	0,58	4,50	7,23	3,80	2,34	6,32	3,38	10,45	6,66	5,85	2,03	6,03	2,89	3,60	0,73	9	60,0%
107_D3	3,65	3,68	1,82	5,14	4,23	4,35	3,36	5,74	2,90	10,98	6,56	8,21	6,08	4,79	3,03	9	60,0%
108_D1	5,30	2,05	8,07	2,41	3,47	9,91	6,64	11,55	7,73	7,93	4,72	8,36	7,19	2,66	1,18	6	40,0%
108_D3	1,26	1,43	0,79	1,36	2,64	2,82	3,79	2,36	4,66	0,28	4,73	3,11	2,50	1,91	2,83	15	100,0%
108_D4	2,06	6,41	2,67	2,90	1,84	0,00	3,37	0,59	2,18	1,16	0,18	1,33	0,77	3,05	0,63	14	93,3%
109_D2	3,00	0,04	1,76	0,04	1,80	0,13	0,33	0,50	0,00	2,53	2,94	4,42	1,15	0,59	1,41	15	100,0%
109_D3	1,82	0,99	1,87	3,33	4,53	3,28	5,43	1,77	4,00	1,18	7,79	6,55	7,26	3,44	6,78	10	66,7%
109_D4	0,07	0,00	0,08	0,53	0,50	0,51	1,15	0,80	1,02	0,60	1,13	0,83	0,20	3,37	0,18	15	100,0%
110_D1	0,83	4,96	9,37	5,12	5,37	8,19	6,64	9,92	6,84	8,96	6,44	4,10	3,95	6,22	3,14	5	33,3%
110_D2	3,61	1,38	1,72	2,31	2,73	2,55	3,23	1,50	1,26	0,72	1,42	0,99	4,91	1,45	3,15	15	100,0%
110_D3	0,05	0,46	1,74	1,76	0,61	2,41	3,39	1,97	1,12	2,48	2,50	0,87	2,17	1,43	1,42	15	100,0%
110_D4	0,00	1,21	4,37	1,13	0,52	0,68	0,04	2,45	3,69	4,75	3,06	4,73	0,89	0,57	1,16	15	100,0%
131_D1	0,75	0,19	0,68	2,75	1,51	1,73	0,00	1,77	0,53	1,54	2,00	3,92	2,73	0,64	0,53	15	100,0%
131_D4	0,54	0,10	2,33	0,56	1,28	0,05	2,32	3,53	1,02	3,40	2,11	1,30	0,28	0,19	1,85	15	100,0%

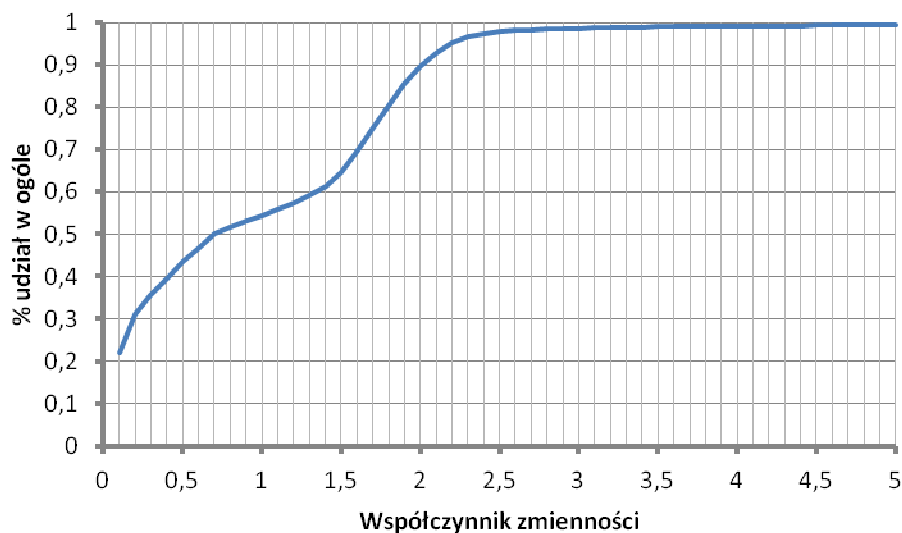
Optimalizacja typu "robust" tras przewozu ładunków na obszarach miejskich- D. Kubek

Nazwa detektora	Godzina															GEH <=5	
	7:00	8:00	9:00	10:00	11:00	12:00	13:00	14:00	15:00	16:00	17:00	18:00	19:00	20:00	21:00	ilość	% udział
132_D1	0,83	3,70	2,53	0,96	1,29	0,09	2,80	1,34	1,73	2,76	1,31	0,25	0,07	1,79	1,82	15	100,0%
191_D1	0,84	3,72	7,34	3,22	4,20	8,19	3,69	11,74	3,70	5,00	2,20	1,48	0,30	4,31	0,73	12	80,0%
191_D3	1,60	2,43	2,47	2,27	2,25	2,97	1,03	4,54	2,52	2,05	2,75	2,37	1,02	1,03	1,75	15	100,0%
191_D4	2,41	1,26	4,02	0,43	0,22	1,60	0,40	0,49	0,34	0,44	0,07	1,48	1,98	2,45	4,11	15	100,0%
321_D1	5,63	0,15	6,31	1,34	1,24	2,06	4,68	1,99	2,07	0,56	3,54	2,37	2,80	2,80	6,87	12	80,0%
321_D2	1,42	3,46	3,38	2,03	0,41	0,94	1,50	0,97	2,14	1,04	0,33	0,20	0,37	0,84	0,55	15	100,0%
321_D3	1,48	6,97	12,74	0,91	2,24	1,38	11,17	11,06	0,52	10,42	0,52	2,66	0,28	0,94	0,29	10	66,7%
321_D4	2,49	2,73	3,05	4,71	7,26	4,56	5,28	5,77	6,77	3,39	2,92	5,10	3,72	5,14	1,12	9	60,0%
323_D1	3,19	3,92	3,68	1,37	2,56	0,00	5,39	2,31	2,87	0,73	1,14	0,95	1,76	3,58	2,44	14	93,3%
324_D4	13,34	1,13	2,88	0,03	2,41	0,95	1,01	3,09	3,18	0,78	0,57	0,07	1,08	0,75	2,61	14	93,3%
325_D2	1,05	6,32	6,01	3,45	2,77	1,28	4,61	2,25	3,64	3,60	1,84	1,36	2,14	0,43	0,25	13	86,7%
325_D4	8,72	1,40	0,24	6,00	4,28	4,36	6,22	1,75	4,39	3,02	1,01	4,61	3,83	6,51	2,58	11	73,3%
326_D2	0,14	4,33	2,67	3,61	2,66	0,33	3,08	0,72	0,81	2,28	1,69	0,80	0,25	0,40	1,32	15	100,0%
326_D3	1,26	2,26	0,35	1,80	1,85	0,91	0,30	0,88	0,82	0,26	2,68	0,05	0,00	2,20	0,90	15	100,0%
326_D4	1,15	1,73	2,04	3,95	0,71	1,20	1,55	2,82	1,17	1,09	3,77	3,39	3,86	2,81	1,30	15	100,0%
327_D1	0,77	3,60	3,26	2,99	1,83	1,39	0,69	0,56	0,51	1,06	1,37	0,30	0,12	0,13	1,49	15	100,0%
327_D2	3,96	8,76	2,34	2,11	6,28	7,09	5,26	4,89	8,97	5,18	4,00	2,30	1,41	4,16	1,23	9	60,0%
327_D3	4,96	0,52	0,37	0,96	0,13	0,13	0,31	0,65	1,53	0,37	1,44	1,44	0,70	1,44	0,47	15	100,0%
327_D4	1,07	2,10	2,47	1,86	0,89	1,34	1,73	0,93	0,93	0,47	3,76	3,06	0,00	0,00	2,95	15	100,0%
328_D1	2,57	8,95	5,73	0,37	1,57	2,02	2,45	8,37	8,28	2,16	1,76	3,59	2,42	1,00	0,87	11	73,3%
328_D2	0,62	6,93	2,37	0,27	0,99	3,30	1,78	0,81	3,01	1,76	1,10	3,06	1,74	0,85	0,04	14	93,3%
328_D4	2,01	1,96	2,45	0,00	1,28	0,16	1,08	1,17	0,84	1,85	0,17	0,69	0,99	1,31	3,93	15	100,0%
430_D1	0,88	0,00	2,16	0,07	0,40	3,16	1,20	5,15	0,36	0,03	0,31	3,00	0,07	0,30	2,32	14	93,3%
430_D2	1,57	5,55	0,25	2,14	0,37	0,45	0,41	0,56	0,07	2,15	1,68	0,43	2,43	1,19	1,63	14	93,3%
430_D4	1,91	0,76	0,52	0,54	1,07	1,15	0,54	0,34	0,92	0,12	1,73	0,52	0,82	3,96	2,93	15	100,0%
GEH <=5	ilość	52	45	42	50	48	45	46	41	47	48	50	47	53	49	54	Ogółem
	% udział	92,86%	80,36%	75,00%	89,29%	85,71%	80,36%	82,14%	73,21%	83,93%	85,71%	89,29%	83,93%	94,64%	87,50%	96,43%	85,36%

Źródło: opracowanie własne.

Wynikiem przeprowadzonych symulacji jest charakterystyka ruchu drogowego analizowanego obszaru wyrażona poprzez czas przejazdu. Czas przejazdu przez poszczególne odcinki drogowe został opisany przez dwie wartości: średnią i odchylenie standardowe. Wartości te zostały obliczone przez symulator na podstawie czasów poruszania się wszystkich symulowanych pojazdów w modelu, które pokonały dany konkretny odcinek w danym interwale czasowym. Przyjęto jednogodzinny interwał generowania statystyki symulowanego ruchu. Odnosząc to do rzeczywistości oznaczałoby to, że zostałyby zmierzony czas przejazdu każdego z pojazdów dla wszystkich odcinków sieci drogowej w danym zakresie dnia. Występujące tu odchylenie od wartości przeciętnej oznacza, że w danej chwili, konkretny odcinek drogi może być pokonany w różnym czasie. Jest to dość oczywiste zjawisko, ponieważ każdy z kierujących pojazdami dostosowuje swoją prędkość poruszania zgodnie z własnymi personalnymi cechami oraz dopasowuje do warunków ruchowych.

W modelu sieci znajduje się 546 odcinków drogowych i do każdego przypisano czasy przejazdu dla każdej godziny w ciągu dnia (15 godzin), co sumarycznie daje 8190 danych opisanych przez średni czas przejazdu oraz odchylenie standardowe od tej wartości. Średnia dla średnich czasów przyjazdu całej populacji danych to 0,4 minuty, odchylenie standardowe wynosi 0,74 minuty, a wariancja 0,55. Zmienność danych można również przedstawić przy pomocy współczynnika zmienności, który wyraża stosunek odchylenia standardowego do wartości średniej. Dla 54,4% wszystkich danych współczynnik zmienności jest mniejszy niż 1; dla ponad 89% wskaźnik ten jest mniejszy niż 2. Oznacza to, że wahania wartości czasu przejazdu, jakie występują na większości odcinkach drogowych sieci jest mniejsza od dwukrotności wartości przeciętnej. Zależność tą przedstawiono na rysunku 5.9, gdzie zaprezentowano funkcję gęstości współczynnika zmienności.




Rysunek 5.9 Funkcja gęstości współczynnika zmienności uzyskanych danych

Źródło: opracowanie własne.

Dodatkowo na rysunku 5.10 przedstawiono przykładową charakterystykę zmiany czasu przejazdu, jaką uzyskano w wyniku symulacji mikroskopowej dla odcinka ulicy Lubicz (do-

jazd do Ronda Mogilskiego). Na wykresie zaprezentowano wartość średnią czasu przejazdu oraz odchylenie standardowe od tej wartości.



Rysunek 5.10 Wykres średniego czasu przejazdu wraz z odchyleniem standardowym w zależności od godziny dnia

Źródło: opracowanie własne.

5.2 CHARAKTERYSTYKA PROBLEMU R-SPP NAJKRÓTSZEJ ŚCIEŻKI ODPORNEJ NA WAHANIA PARAMETRÓW

5.2.1 ZBIÓR DANYCH TESTOWYCH

W oparciu o główne założenie, jakim jest integracja modelu odpornego problemu najkrótszej ścieżki z problemem wyznaczania tras pojazdów z elastycznymi oknami czasowymi, istotne jest zbadanie charakterystyki oraz użyteczności modelu (RC_{SPP}^e). W tym celu dokonano analizy na trzech zbiorach danych:

- Zbiory losowo wygenerowane - nazwy przypadków: R-100, R-225, R-400, R-625, R-900 oraz R-1225,
- Kraków (centrum) - rzeczywista sieci drogowa z czasami przejazdu wygenerowanych przez symulator ruchu drogowego,
- Kraków - duża rzeczywista sieć drogowa z losowymi czasami przejazdu zależnymi od długości odcinka i dopuszczalnej prędkości.

Pierwsze zbiory zostały stworzone w pełni losowo, przy założeniach: kształt sieci to tzw. układ manhattański, gdzie dane o oczekiwanym czasie przejazdu zostały wygenerowane z rozkładu jednostajnego dla zakresu [1,5] min. Wartość odchyłeń czasów przejazdu ustalono, jako losowo zależne od wartości oczekiwanej czasu przejazdu z zakresu [100%, 200%]. Drugi zbiór danych został stworzony w oparciu o założenia przedstawione w poprzednim podrozdziale. Zbiór ten jest modelem rzeczywistej sieci drogowej centrum miasta Krakowa, a dane ruchowe zostały wygenerowane przy pomocy symulatora AIMSUN 8. Przeprowadzone symulacje zostały skalibrowane z rzeczywistym pomiarem przekrojowym - osiągnięto średnią zgodność modelu na poziomie $R^2 = 87,67\%$, a wskaźnik GEH uzyskano mniejszy od 5 dla 85,36% przypadków, co świadczy o statystycznej zgodności modelu. Ostatni zbiór danych to

model aglomeracji krakowskiej, zaprezentowany w pracy [131]. W związku z brakiem możliwości pozyskania danych dotyczących rzeczywistych czasów przejazdów na poszczególnych odcinkach, dane te zostały wygenerowane przy założeniach: oczekiwany czas przejazdu został obliczony, jako stosunek rzeczywistej długości odcinka do dopuszczalnej prędkości. Odchylenie od wartości oczekiwanej zostało losowo wybrane z rozkładu jednostajnego zakresu [20%, 70%] czasu oczekiwanego. Zbiór niepewności dla powyższych zbiorów danych został opisany przez wartość oczekiwaną oraz odchylenie standardowe zgodnie z modelem (MIP_u). Model został zapisany w języku MATLAB przy użyciu bezpłatnego zestawu narzędzi ROME 1.0.9, który umożliwia m.in. konwersję i eksport modeli matematycznych do zewnętrznych narzędzi optymalizacyjnych. Proces optymalizacji został wykonany przez specjalistyczne oprogramowanie CPLEX 12.5, którego działanie jest oparte na algorytmie podziału i ograniczeń (ang. Branch and Bound).

5.2.2 UŻYTECZNOŚĆ MODELU

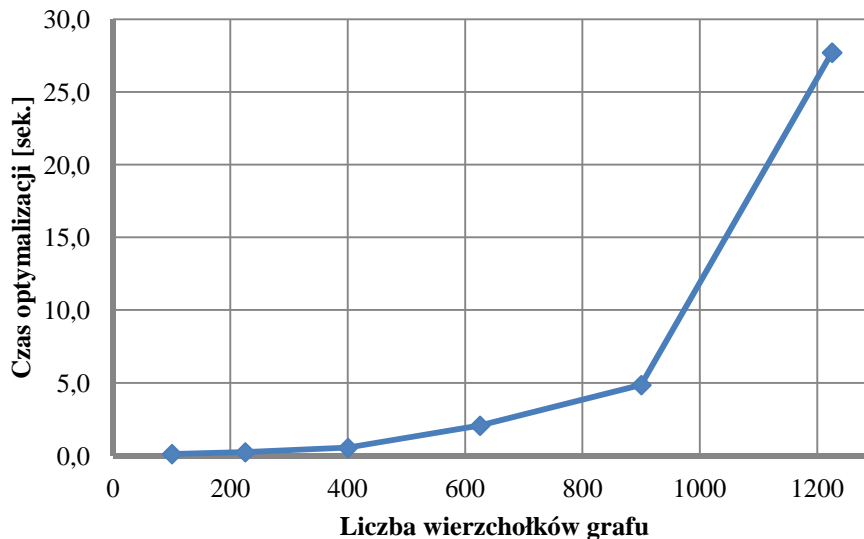
Pierwsze badanie miało na celu sprawdzenie, jaki jest średni czas optymalizacji danego przypadku w zależności od wielkości analizowanej sieci. Wyniki przedstawiono w tabeli 5-5 oraz na rysunku 5.11, gdzie przedstawiono czas obliczeń dla losowo wybranej pary punktów w analizowanej sieci. Dane w tabeli oznaczone gwiazdką wskazują, że algorytm nie odnalazł rozwiązania optymalnego, a pracę zakończył przez osiągnięcie kryterium stopu, jakim był czas obliczeń równy 60 [sek.].

Cechą charakterystyczną problemów typu NP-trudny jest wykładniczy wzrost czasu obliczeń w stosunku do wielkości grafu. Dodatkową własnością takich modeli jest możliwość wskazania punktu granicznego, po przekroczeniu, którego czas optymalizacji rośnie znacząco i jest on nieakceptowany. W analizowanym przypadku użyteczność modelu (RC_{SPP}^*), w zastosowaniu do dalszych analiz problematyki VRP, można wskazać na ok. 500 wierzchołków grafu. Dla takiej liczby punktów w grafie, czas optymalizacji wynosi poniżej 1 sekundy. Szybkość uzyskania rozwiązania jest istotna, z uwagi na fakt wykorzystywania modelu do obliczania najkrótszych połączeń pomiędzy wszystkimi parami klientów.

Tabela 5-5. Czas obliczeń w zależności od rozmiaru sieci oraz od parametru kontroli poziomu konserwatywności.

Przypadek	Liczba wierzchołków	Liczba łuków	Czas obliczeń [sek.]									Średnia	
			$\Gamma^{SP}=0$	$\Gamma^{SP}=10$	$\Gamma^{SP}=20$	$\Gamma^{SP}=30$	$\Gamma^{SP}=40$	$\Gamma^{SP}=50$	$\Gamma^{SP}=60$	$\Gamma^{SP}=70$	$\Gamma^{SP}=80$		
R-100	100	360	0,11	0,12	0,12	0,11	0,11	0,11	0,11	0,11	0,11	0,11	0,11
R-220	225	840	0,16	0,39	0,38	0,25	0,23	0,20	0,18	0,18	0,19	0,19	0,23
R-400	400	1520	0,35	0,49	1,24	0,69	0,44	0,41	0,61	0,41	0,43	0,43	0,53
R-625	625	2400	0,69	1,73	8,92	3,22	1,94	1,43	1,07	0,96	0,90	0,90	2,06
R-900	900	3780	1,36	2,85	7,06	12,41	6,33	12,16	2,71	2,54	2,07	2,07	4,86
R-1225	1225	4760	2,34	5,83	60,90*	60,97*	60,94*	21,57	60,95*	12,67	9,10	9,10	27,71
Kraków (centrum)	250	546	0,18	0,18	0,18	0,18	0,19	0,17	0,18	0,18	0,17	0,17	0,18
Kraków	2101	5094	8,73	12,06	11,95	11,82	13,81	13,04	13,62	14,14	11,01	11,01	12,17

Źródło: opracowanie własne.

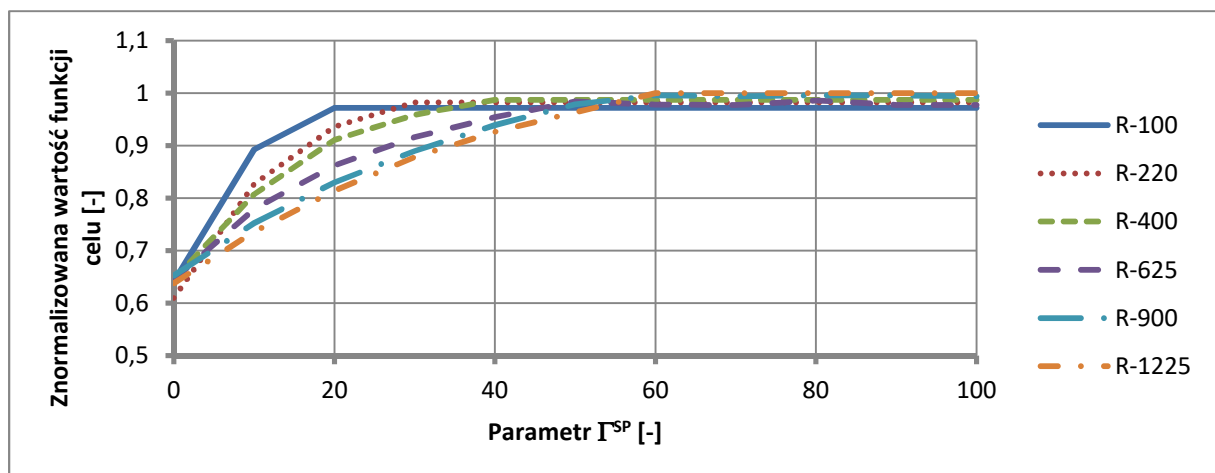


Rysunek 5.11. Średni czas optymalizacji modelu (RC_{SPP}^*) w zależności od wielkości sieci.

Źródło: opracowanie własne.

5.2.3 WPŁYW PARAMETRU KONSERWATYZMU NA ROZWIĄZANIE W MODELU (RC_{SPP}^e)

W tabeli 5-5 przedstawiono również zależność czasu optymalizacji od wartości parametru poziomu konserwatyizmu I^{SP} . Wartość tego parametru wpływa na czas obliczeń, jednak wpływ ten jest do pewnej wartości. Granica ta jest wyznaczona przez moment przejścia modelu (RC_{SPP}^e) w model optymalizacji typu min-max. Sytuację tą może wyjaśnić kolejny rysunek 5.12, który przedstawia zmianę wartości funkcji celu w zależności od wartości I^{SP} . Wykres jest sporządzony dla wygenerowanych zbiorów losowych. Przy odpowiednio dużym poziomie wartości I^{SP} algorytm optymalizacyjny poszukuje rozwiązania, które by spełniało warunki modelu dla pełnego zakresu zmienności parametrów czasu przejazdu \tilde{T}^{SP} . Granica przekształca się w poszukiwanie rozwiązania typu najlepszy z najgorszych, jest indywidualna dla każdego przypadku. Jednak mając na uwadze ograniczenia (4.35) modelu można wywnioskować, że jest ona określona przez liczbą łuków występujących w rozwiązaniu (w ścieżce).



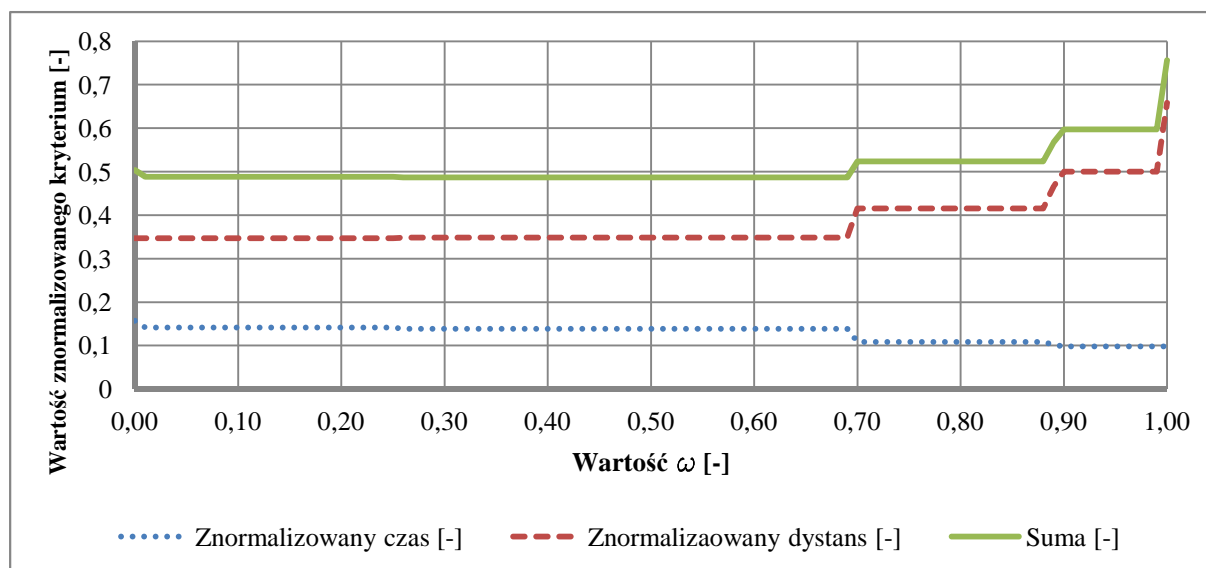
Rysunek 5.12. Zależność wartości funkcji celu modelu (RC_{SPP}^*) od parametru I^{SP} .

Źródło: opracowanie własne.

Wzrost wartości funkcji celu jest spowodowany uwzględnieniem możliwych odchyłek od wartości oczekiwanej i jak już to wspomniano wcześniej, w literaturze przedmiotu wzrost ten nazywa się "ceną uodpornienia". W takiej formule, ścieżka odporna często charakteryzuje się wydłużeniem długości trasy, w celu zmniejszenia ryzyka pojawienia się nieoczekiwanych odchyłek w czasie jazdy. Wynik ten jest dość intuicyjny i mocno nawiązujący do rzeczywistości, ponieważ w ruchu miejskim często dochodzi do sytuacji, że opłaca się wybrać trochę dłuższą trasę, a szybszą, niż krótką i możliwie dłuższą czasowo, gdzie istnieje wysokie ryzyko, że mogą wystąpić nagłe zmiany parametrów ruchu.

5.2.4 WPŁYW WAGI FUNKCJI KRYTERIALNEJ NA ROZWIĄZANIE W MODELU (RC_{SP}^e)

W modelu (RC_{SP}^e) występuje jeszcze jeden parametr, którego wartość może istotnie wpływać na proces optymalizacji. Jest nim waga ω^{SP} , czyli kryterium cząstkowego w funkcji celu. Ustalenie jego wartości w głównej mierze zależy od decydenta, czy też polityki transportowej danej firmy, jednak świadomość jak on wpływa na rozwiązanie jest kluczowa. Rysunek 5.13 przedstawia tę zmianę znormalizowanych kryteriów cząstkowych w zależności od wartości wagi ω^{SP} w funkcji kryterialnej (4.29). Analiza została wykonana dla losowej pary wierzchołków grafu dla przypadku Kraków (centrum) przy poziomie konserwatywności $\Gamma^{SP} = 10$.



Rysunek 5.13. Zmienność znormalizowanych kryteriów cząstkowych modelu (RC_{SP}^e) w zależności od wagi ω^{SP} .

Źródło: opracowanie własne.

Rozbieżność wartości cząstkowych kryteriów jest dość oczywistym wnioskiem. Im waga ω^{SP} jest większa, tym algorytm optymalizacyjny jest bardziej ukierunkowany na odnalezienie ścieżki o najmniejszym czasie jazdy. Dla wartości granicznych model (RC_{SP}^e) staje się jednokryterialny, czyli: $\omega^{SP} = 0$ - minimalizacja dystansu, $\omega^{SP} = 1$ - minimalizacja czasu jazdy. Drugi wniosek, jaki można zaobserwować, jeśli długość ścieżki maleje, to czas realizacji ścieżki wzrasta. Skokowa zmienność wartości funkcji celu oznacza zmianę przebiegu ścieżki pomiędzy punktami $\{org, des\}$. W tych punktach następuje odnalezienie innej ścieżki - w analizowanym przypadku nastąpiło to 6 razy. Jak można zauważyć "skłonność" do częstszej zmiany przebiegu ścieżki dla analizowanego przykładu następuje dla $\omega^{SP} > 0,7$. Dla

innych przypadków granica ta waha się w zakresie: $\omega^{SP} \in [0,5; 0,8]$. Efekt ten jest wynikiem wprowadzenia niepewności w czasie przejazdu oraz faktu, że dystans pomiędzy wierzchołkami jest niezmienny. Dla mniejszych wartości kryterium dystansu jest dominujące i odnalezione rozwiązania, charakteryzują się najmniejszą długością.

Charakterystyka ta może być pierwszym wskazaniem przydatności stosowania modeli odpornych w wyznaczaniu tras pojazdom. Jeśli firma transportowa jest ukierunkowana w dużej mierze na pracę przewozową, wyrażoną przez liczbę pokonanych tonokilometrów, stosowanie modeli z niepewnymi czasami przejazdów może nie mieć sensu. Jeśli jednak dla danej firmy ważny jest również czas operacyjny, który istotnie wpływa na obsługę klientów i czas pracy kierowców oraz poziom emisji spalin, stosowanie modeli niepewnych może być interesujące. Jak wspomniano, to wcześniej, z przeprowadzonego wywiadu z firmami transportowymi wynika, że czas przejazdu jest ważniejszy niż dystans w stosunku odpowiednio: 0,75/0,25. Świadczy to, więc o możliwości wykorzystania modeli odpornych w rzeczywistości.

5.2.5 POZYTYWNE I NEGATYWNE ASPEKTY STOSOWANIA ROZWIĄZAŃ MODELU (RC_{SPP}^e)

Ostatnią analizą, jaką wykonano to sprawdzenie, jakie pozytywne i negatywne efekty może przynieść uwzględnianie niepewności przy wyznaczaniu ścieżek w mieście. W tym celu wykonano analizę na rzeczywistej sieci drogowej centrum miasta Krakowa. Dane ruchowe uzyskano jak w poprzednich analizach. Dla 20 losowo wybranych wierzchołków grafu obliczono wszystkie możliwe kombinacje połączeń, w sumie 380 wariantów. Do obliczenia połączeń między nimi wykorzystano model (RC_{SPP}^e) z poziomem konserwatyźmu: $\Gamma^{SP} = 0$, czyli wersję deterministyczną oraz $\Gamma^{SP} = 10$, czyli wersję odporną na wahania parametrów. Zbiór zmienności zdefiniowano, jako przedział określony przez wartość średnią czasu przejazdu w całym dniu i przez odchylenie od tej wartości przyjęte, jako maksymalna wartość czasu przejazdu dla godzin 15:00 - 18:00. Dla Krakowa godziny te są utożsamiane ze szczytem komunikacyjnym popołudniowym. W analizie przyjęto wersję deterministyczną, jako punkt odniesienia - parametrami modelu był średni czas przejazdu w ciągu danego dnia.

W związku z tym, że ruch miejski jest dynamiczny i trudny do przewidzenia oraz planowanie przebiegu ścieżek/tras odbywa się w oparciu o prognozy, obliczono dwa warianty porównawcze. W pierwszym wariantcie sprawdzono, jaki byłby koszt ścieżki deterministycznej i odpornej gdyby wystąpiły założone odchylenia od wartości średniej. Można to porównać do sytuacji, gdy prognoza czasu przejazdu sprawdziłaby się w stu procentach z rzeczywistymi parametrami ruchowymi. Drugi wariant to porównanie kosztów ścieżek, gdyby założone wartości wahań wartości czasu przejazdu byłyby różne od wartości zrealizowanych w rzeczywistości. Jest to sytuacja, gdy wartości prognozy odbiegają od rzeczywistych wartości parametrów. Różnice pomiędzy wartością założoną, a zrealizowaną to wartość wygenerowana z przedziału: $[0,5; 1,5]$ wartości odchylenia od średniej. Wagę w funkcji celu przyjęto zgodnie z pozyskanymi informacjami od firmy transportowej, czyli: $\omega^{SP} = 0,75$. Dla obu wersji obliczono również jak zmieniła się długość ścieżki.

W tabeli 5-6 przedstawiono wyniki analizy. Redukcja została wyznaczona w odniesieniu do wersji deterministycznej, zgodnie z zależnością:

$$RED = \frac{F_{DET} - F_{ROB}}{F_{DET}} [\%] \quad (5.2)$$

Gdzie:

RED - redukcja kosztu w odniesieniu do wersji deterministycznej. Ujemna wartość oznacza zwiększenie kosztów przez rozwiązanie odporne na wahania.

F_{DET} - koszt ścieżki dla wersji deterministycznej (czas lub dystans),

F_{ROB} - koszt ścieżki dla wersji odpornej (czas lub dystans).

Tabela 5-6. Pozytywne i negatywne aspekty stosowania (RC_{SPP}^e) w odniesieniu do deterministycznego modelu (SPP) dla czasu trwania oraz długości ścieżki.

Redukcja [%]	Czas								Dystans			
	Wariant 1				Wariant 2							
	Ilość	Min.	Średni	Maks.	Ilość	Min.	Średni	Maks.	Ilość	Min.	Średni	Maks.
Pozytywna	66	0,77	9,40	37,31	57	0,00	11,98	54,35	21	0,78	1,95	5,03
Negatywna	6	-5,08	-4,39	-3,92	16	-20,13	-8,04	-0,14	51	-18,89	-6,55	-0,63
Neutralna	308	0,00	0,00	0,00	307	0,00	0,00	0,00	308	0,00	0,00	0,00
	Średnia			8,25	Średnia			7,59	Średnia			-4,07

Źródło: opracowanie własne.

Uwzględnienie możliwości zmiany czasu przejazdu przy planowaniu ścieżek pozytywnie wpływa na uzyskane rozwiązanie. Wprawdzie dla większości przypadków rozwiązanie nie zmieniło się jednak prawie, co piąta ścieżka deterministyczna okazała się gorsza niż wersja odporna na wahania. Co więcej możliwa do uzyskania średnia redukcja czasu w "Wariancie 1" to 8,25%, a maksymalna 37,31%. W zaledwie 6 przypadkach rozwiązanie odporne okazało się gorsze od deterministycznego, jednak straty czasu są mniejsze, bo maksymalnie wyniosły nieco ponad 5%. W "Wariancie 2" możliwe zyski czasu rosną wraz ze wzrostem ryzyka, o czym świadczy potencjalna redukcja czasu. Dla obu wariantów możliwe zyski czasu trwania ścieżki są uzyskiwane kosztem pokonanego dystansu. Średnio, co trzecia ścieżka wykazująca pozytywną redukcją czasu, charakteryzuje się ujemną redukcją dystansu. Rezultat ten jest podobny do poprzednich wniosków, czyli wybór ścieżki o potencjalnie mniejszym czasie przejazdu jest obarczone zwiększeniem pokonanego dystansu. Jednakże, podsumowując możliwe do uzyskania zyski czasu trwania ścieżek są większe niż możliwe do poniesienia kosztów związanych z długością trasy. Wniosek ten jest dość istotny z punktu widzenia firm, dla których jakość wykonywanych usług transportowych jest ważna. Uwzględnianie niepewności parametrów ruchu przy wyznaczaniu ścieżek/tras może zwiększyć efektywność właściwego czasu rozpoczęcia obsługi transportowej.

Przy wyznaczaniu ścieżek w warunkach miejskich stosowanie modeli niepewnych przynosi pozytywne efekty. Biorąc pod uwagę założenie, że wyznaczenie odpornych najkrótszych ścieżek jest podstawą w problematyce wyznaczania tras pojazdom, można przypuszczać, że potencjalne zyski mogą być, na co najmniej podobnym poziomie. Przypuszczenie to, w dalszej części pracy, jest tezą do zweryfikowania.

5.3 ANALIZA PARAMETRÓW MODELI (*nVRP1*) ORAZ (*nVRP2*)

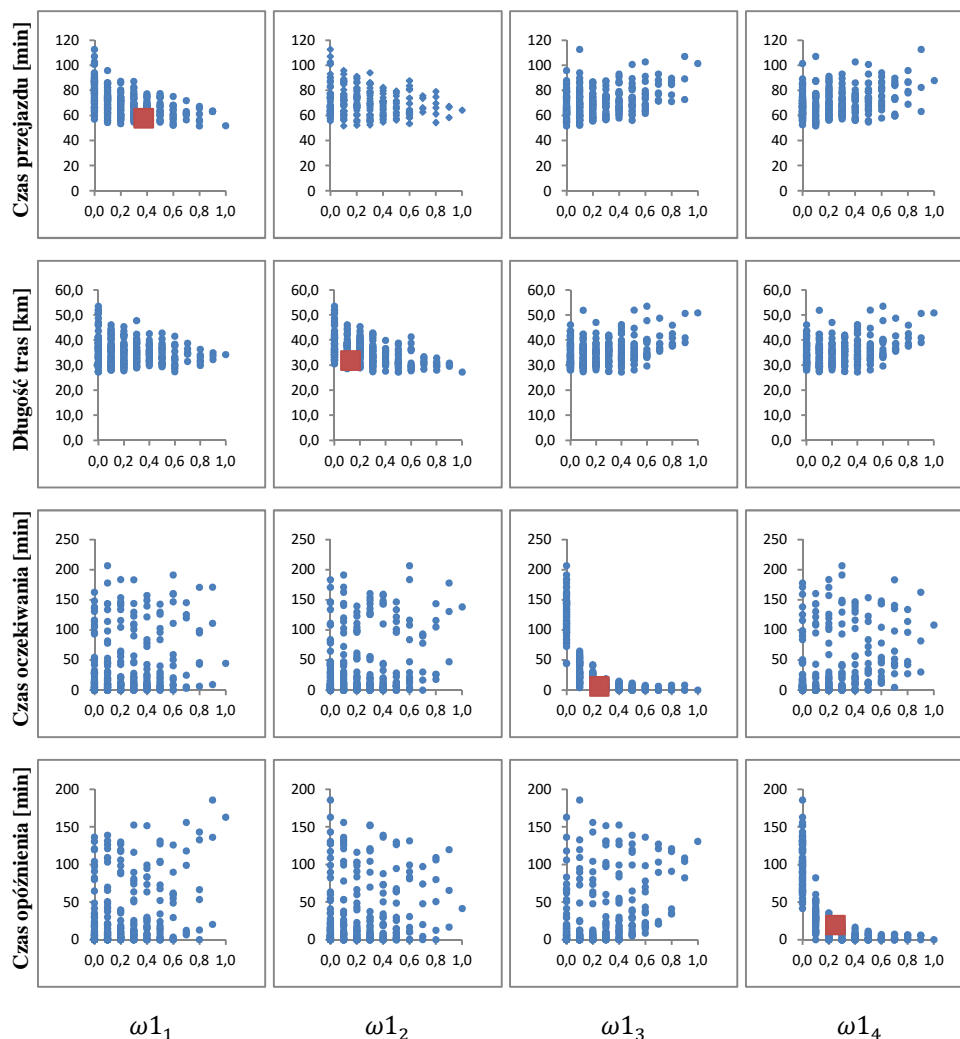
5.3.1 WPLYW WAGI KRYTERIÓW NA ROZWIĄZANIE MODELI (*nVRP1*) ORAZ (*nVRP2*)

Przed przystąpieniem do analizy podejścia integracji problemów R-SPP i VRP-STW, zbadano wpływ wartości wag kryteriów cząstkowych Ω_1 i Ω_2 na rozwiązanie. Badanie wykonano na danych odnoszących się do rzeczywistej sieci drogowej przedstawionej w podrozdziale 5.1. Dla 20 klientów okno czasowe obsługi, popyt, podaż, czas obsługi oraz umiejscowienie w sieci było wygenerowane losowo z rozkładu normalnego. Wielkość popytu i podaży przypisano do klientów losowo z przedziału [5;20] kg. Pojemność pojazdów $Q = 1000$ kg. Założono, że okna czasowe są o szerokości 2 godziny, a elastyczne okna czasowe są obustronnie szersze od stałego okna czasowego o 30 min. Czas obsługi waha się w granicach od 5 do 10 min. Przyjęto, że potencjalne wartości wag mogą być wybrane z dyskretyzowanego przedziału [0; 1] z krokiem 0,1. W celu dokonania przeglądu jak wartości wag wpływają na jakość rozwiązania, obliczono wszystkie możliwe wariacje podczas wybierania 4 i 5 elementów ze dyskretyzowanego zbioru potencjalnych wartości wag. Dla pierwszej wersji modelu z ponad 14 tys. wariacji wybrano 266, a dla drugiej wersji modelu z ponad 160 tys. wariacji wybrano 896, których suma elementów w obu przypadkach dała wartość równą 1 (zgodnie z założeniami 4.25 i 4.28).

Z uwagi na fakt, że liczba wag ze zbioru Ω_1 jest równa cztery, a zbioru Ω_2 jest równa pięć, analiza sprowadza się do zbadania cztero- i pięciowymiarowej przestrzeni, co wizualnie nie jest możliwe do przedstawienia. Z tego powodu, analizę wykonano korzystając z metody porównywania parami wykorzystując wykresy punktowe. Wyniki analizy przedstawiają: rysunek 5.14 oraz rysunek 5.15, gdzie na osiach pionowych są wartości poszczególnych kryteriów, a na osiach poziomych wartości poszczególnych wag kryteriów.

Interpretując rysunek 5.14 można wyciągnąć wnioski (niektóre dość intuicyjne):

1. Rozważania każdego z kryteriów osobno (w formie jednokryterialnej) prowadzi do zwiększania wartości pozostałych kryteriów,
2. Przeszukiwanie przestrzeni rozwiązań mając na uwadze tylko kryteria: f_3^{VRP}, f_4^{VRP} lub rozważanie ich z dużym poziomem ważności może prowadzić do uzyskiwania rozwiązania o wysokim koszcie czasu i dystansu. Świadczy o tym duże rozproszenie danych na wykresach: w pierwszym, drugim wierszu i w trzeciej, czwartej kolumnie (dalej skrótowy zapis: wykresy {1,2} x {3,4}),
3. Pomimo zwiększania wartości wagi ω_1 , na rzecz wagi ω_2 i odwrotnie, można zauważyć trend zmniejszania wartości obu korespondujących funkcji kryterialnych (wykresy: {1,2} x {1,2}). Istnieje znaczna korelacja pomiędzy czasem trwania tras, a długością tras - dla analizowanego przypadku współczynnik determinacji wyniósł: $R^2 = 68,61\%$.
4. Przeszukiwanie przestrzeni rozwiązań bez rozważania kryteriów f_3^{VRP}, f_4^{VRP} prowadzi do rozwiązania, w którym obsługa klienta odbędzie poza wyznaczonym sztywnym oknem czasowym (wykresy: {3,4} x {1,2}).

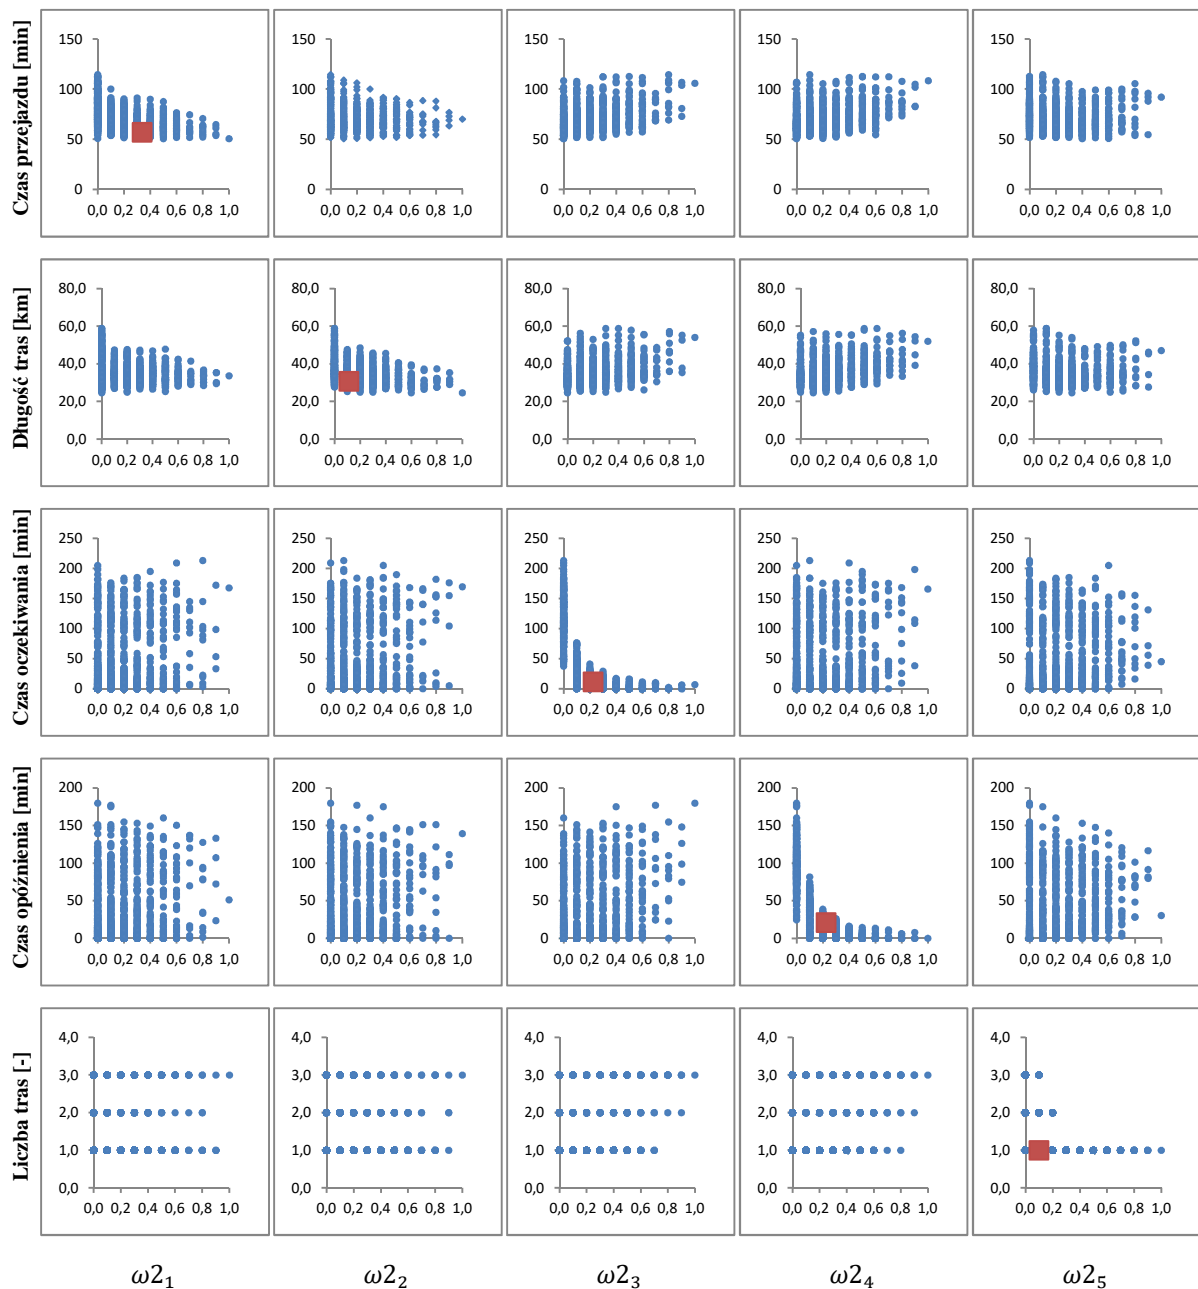


Rysunek 5.14. Wykresy punktowe wartości kryteriów cząstkowych w zależności od wartości wag kryteriów dla modelu (nVRP1).

Źródło: opracowanie własne.

Sposób doboru wag kryteriów zawsze jest subiektywny i jest zdeterminowany w głównej mierze przez wiedzę decydenta procesu planistycznego. Stąd na podstawie informacji od firm transportowych (rozdział 4) określono wartości wag kryteriów, które odpowiadałyby rzeczywistemu procesowi decyzyjnemu. Dla modelu (nVRP1) przyjęto, że elementami zbioru wag kryteriów będą wartości: $\Omega_1^* = \{0,375; 0,125; 0,25; 0,125\}$. Stosunek ω_1/ω_2 wynosi 75/25, a pomiędzy ω_1/ω_3 lub ω_1/ω_4 wynosi 60/40, czyli zgodnie z informacjami otrzymanymi z wywiadu. Założono, że czas oczekiwania jest tak samo kosztowny jak czas opóźnienia: $\omega_3 = \omega_4$. Na rysunku 5.14 przedstawiono rozwiązanie dla takich wartości wag - czerwony punkt w kształcie kwadratu. Zaprezentowane rozwiązanie dowodzi, że wiedza ekspercka planistów transportu umożliwia otrzymanie rozwiązania w analizie wielokryterialnej dobrej jakości. Świadczy o tym dość bliskie położenie punktów w poszczególnych kryteriach względem rozwiązań optymalnych dla każdego z kryteriów cząstkowych z osobna (wykresy na przekątnej).

Analogiczną analizę wpływu wag kryteriów cząstkowych na rozwiązanie dokonano dla modelu drugiego - (*nVRP2*), w którym liczba pojazdów jest zmienna, ale ograniczona górną granicą *K*. W przykładzie przyjęto, że można użyć co najwyżej 3 pojazdy.



Rysunek 5.15. Wykresy punktowe wartości kryteriów cząstkowych w zależności od wartości wag kryteriów dla modelu (*nVRP2*).

Źródło: opracowanie własne.

Porównując wyniki z pierwszej wersji modelu z drugą, można zaobserwować, że wpływ wag kryteriów na sposób poszukiwania rozwiązania przez algorytm jest taki sam. Również istnieje znaczna korelacja pomiędzy czasem trwania tras, a długością tras - dla analizowanego przypadku współczynnik determinacji wyniósł: $R^2 = 74,17\%$. Przyjęcie niedużej wartości wagi tu: $\omega_5 \geq 0,2$ dla f_5^{VRP} powoduje, że wartość tego kryterium jest optymalna (wykres {5} x {5}). Na podstawie tej obserwacji oraz wyznaczonych wartości wag Ω_1^* , wyznaczono zbiór

wag kryteriów dla modelu ($nVRP2$): $\Omega_2^* = \{0,3375; 0,1125; 0,2250; 0,2250; 0,1000\}$. Rozwiązanie dla takich wartości przedstawiono na wykresach w postaci czerwonych kwadratów. Podobnie jak w pierwszej wersji problemu, zaproponowane wagi dają dobrej jakości rozwiązanie.

W kolejnym etapie analiz sprawdzono jakie jest odniesienie rozwiązania otrzymanego z wartościami wag Ω_2^* z innymi możliwościami. Tabela 5-7 zawiera porównanie rozwiązania przy założeniu wartości Ω_2^* , z wartościami rozwiązania wielokryterialnego idealnego oraz poszczególnych rozwiązań jednokryterialnych. Poprzez rozwiązanie idealne rozumiane jest rozwiązanie, którego poszczególne wartości kryteriów cząstkowych odpowiadają wartościom rozwiązań dla kryteriów z osobna (optymalizacja jednokryterialna). Zazwyczaj punkt ten nie jest osiągalny, ma on jedynie charakter punktu odniesienia (szczególnie jest to wykorzystywane w programowaniu celowym). Koszty rozwiązań jednokryterialnych określono następująco: spośród zbioru rozwiązań z poprzedniej analizy wybrano rozwiązania, których wartości były najmniejsze ze względu na dane kryterium. Wyniki tej analizy przedstawiają kolumny od 2 do 6 w tabeli 5-7.

Tabela 5-7. Porównanie wartości wag kryteriów w rozwiązaniu idealnym.

	Odniesienie - punkt idealny	Optimum - f_1^{VRP}	Optimum - f_2^{VRP}	Optimum - f_3^{VRP}	Optimum - f_4^{VRP}	Optimum - f_5^{VRP}	Ω
Czas [min]	50,7	50,7	70,2	105,9	108,5	92,1	57,1
Długość [m]	24 646,5	33 702,1	24 646,5	54 116,7	52 007,1	47 092,1	30 717,3
Oczekiwanie [min]	0,0	167,6	169,5	0,0	165,6	45,1	11,4
Opóźnienie [min]	0,0	51,2	139,1	179,7	0,0	30,3	20,9
Liczba tras [-]	1	3	3	3	3	1	1


Źródło: opracowanie własne.

Przyjęte wartości wag dla danego kryterium cząstkowego tworzy kompromis pomiędzy wszystkimi celami funkcji. Jak można zaobserwować, opis ważności kryteriów uzyskany od osób zajmujących się, na co dzień planowaniem transportu umożliwia zdefiniowanie wektora wag, który daje dobrej jakości rozwiązanie. Sformułowanie "dobrej jakości" jest oczywiście oceną subiektywną, jednak jak można zauważyć, otrzymane rozwiązanie jest tylko o kilkanaście procent gorsze od punktu idealnego, który może nie być rozwiązaniem dopuszczalnym.

Powyższa analiza ponownie potwierdza właściwość problemów VRP - w odniesieniu do rzeczywistych procesów ukierunkowanie się na jeden cel może powodować zwiększanie się kosztów w innych elementach procesu. Przedstawione wnioski w dość ogólny sposób wyznaczają zależności pomiędzy kryteriami cząstkowymi. Jednak, co najistotniejsze, dowodzą zasadność przyjęcia założenia o wprowadzeniu w modelach VRP wielokryterialności.

5.3.2 UŻYTECZNOŚĆ MODELI ($nVRP1$) ORAZ ($nVRP2$)

Przy rozwiązywaniu problemów kombinatorycznych bardzo ważnym elementem jest informacja o użyteczności danego modelu. W problematyce VRP wyraża się ją przede wszystkim poprzez czas optymalizacji, który jest silnie uzależniony od wielkości rozważanego problemu, ale nie tylko. Analizę wpływu parametrów modelu na czas obliczeń wykonano na wspomnianym zbiorze danych "Kraków centrum". Dla losowo wybranych zbiorów klientów został sprawdzony czas wykonywania optymalizacji w zależności od liczebności klientów, liczby potencjalnej floty pojazdów, szerokości okien czasowych oraz od przyjętej wersji modelu. Liczebność klientów została wybrana z przedziału $[20; 80]$ z krokiem co 5, co daje 13 przypadków. Lokalizacja klientów została wygenerowana losowo, przyjmując, że umiejscowienie ich w sieci jest na łukach grafu. Przypisanie to zostało wykonane przez utworzenie dodatkowych, wirtualnych wierzchołków grafu, które dzielą oryginalne łuki grafu na równe części. I tak dla przykładu, jeśli analizowany jest przykład z 80 klientami w rozważanym obszarze, to graf reprezentujący ten przypadek będzie składał się z 331 wierzchołków (251 sieci drogowej plus 80 wirtualnych klientów) oraz z 644 łuków (564 łuków sieci drogowej plus 80 dodatkowych łuków). Przykładową lokalizację 80 klientów przedstawia rysunek 5.16.



Rysunek 5.16 Przykładowa lokalizacja 80 klientów (czerwone kwadraty) w reprezentacji grafowej analizowanej sieci drogowej.

Źródło: opracowanie własne.

Dla każdego z przypadków wygenerowano losowo z rozkładu normalnego charakterystyki klientów, zakładając dystrybucję drobnicową towarów scharakteryzowaną przez informacje uzyskane od firm transportowych. Czas pracy magazynu to: $[E, L] = [6; 21]$, w tych godzinach pojazdy mogą wyjeżdżać i powracać do magazynu. Pojazdy posiadają ładowność 1000 kg. W każdym zbiorze klientów można wyznaczyć maksymalnie 5 tras.

Charakterystykę okien czasowych obsługi klientów przypisano losowo w dwóch wersjach:

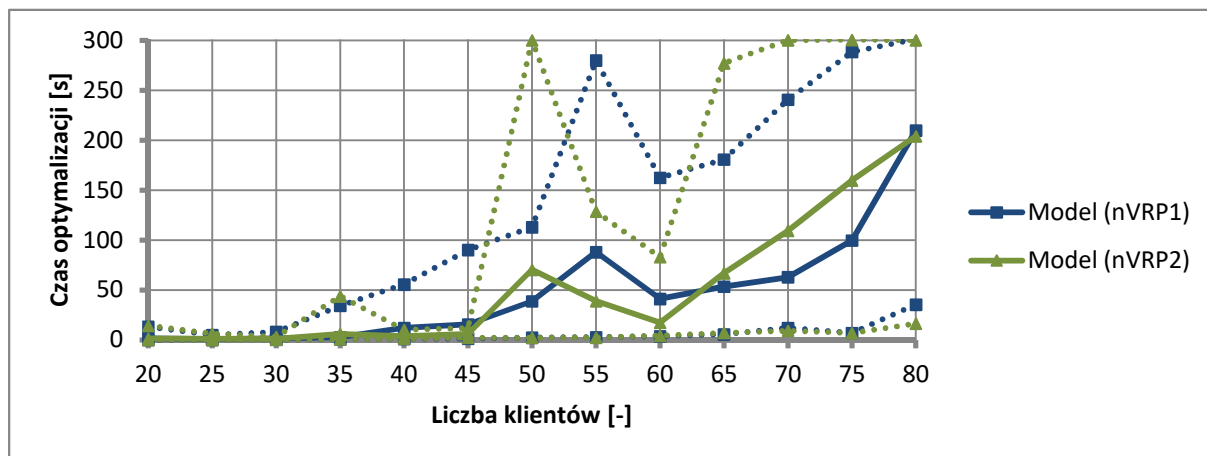
- "okna - wszyscy" - gdzie wszyscy klienci mogą być obsłużeni w określonym czasie,

- "okna - mieszane" - gdzie tylko część klientów ma przypisany preferowany czas obsługi. Przyjęto, że od 30% do 50% klientów nie posiada przypisanych własnych okien czasowych - obsługa musi być wykonana w czasie pracy magazynu, czyli w ciągu całego dnia.

W obu wersjach okna czasowe zostały sformułowane w postaci symetrycznych, elastycznych okien (założenia w podrozdziale 4.1.1), zakładając, że pierwsze i ostatnie pół godziny to czas, gdy są ponoszone koszty związane ze zbyt wczesnym/późnym przyjazdem kierowcy. Pozostałe dwie godziny pełnią rolę właściwych, preferowanych okien obsługi, w ramach, których nie występują dodatkowe koszty. Formalnie można zapisać: $|tw_i| = 2, |tw_i^\#| = 3, \forall i \in VP_C$.

Przyjmując powyższe założenia, wygenerowano 260 przykładów testowych (2 rodzaje modeli * 2 wersje okien * 13 przypadków liczebności klientów * 5 tras). Zbieżność algorytmu optymalizującego programu CPLEX 12.5 została wyznaczona przez dwa warunki: pierwszy, osiągnięcie względnej różnicy 1% pomiędzy najlepszym rozwiązaniem całkowitoliczbowym w węzle drzewa decyzyjnego algorytmu, a bieżącym rozwiązaniem; drugi warunek, maksymalny czas obliczeń to 5 min. Wyniki symulacji przedstawiono na poniższych wykresach. Jeśli algorytm osiągnął maksymalny czas, punkty na wykresie mają przypisaną wartość 300 sekund. Z kolei, jeśli algorytm po 5 minutach obliczeń nie odnalazł rozwiązania całkowitoliczbowego, wartości na wykresach zostały pominięte.

Dla wszystkich przykładów testowych określono minimalny, średni i maksymalny czas optymalizacji. Na rysunku 5.17 zaprezentowano porównanie obu zaproponowanych modeli VRP.



Rysunek 5.17 Średni czas optymalizacji w zależności od liczby klientów i przyjętego modelu VRP.

Źródło: opracowanie własne.

Linie przerywane reprezentują zakres zmian czasu optymalizacji (minimalny i maksymalny czas). Na podstawie średniej nie jest możliwe wskazanie, który model jest lepszy pod względem czasu optymalizacji. Wysoki zakres zmienności czasu obliczeń dla poszczególnych przypadków wynika z dwóch kwestii: zakładanej liczby pojazdów (tras) oraz specyfiki okien

czasowych³⁶. Potwierdzeniem tych wniosków są dane w tabeli 5-8 i tabeli 5-9 oraz kolejne wykresy - rysunek 5.18 oraz rysunek 5.19.

Tabela 5-8 Średni czas optymalizacji dla modeli (*nVRP1*) oraz (*nVRP2*) w zależności od liczby klientów i zakładanej liczby tras.

Liczba tras		Czas optymalizacji [s]											
		Model (<i>nVRP1</i>)						Model (<i>nVRP2</i>)					
		K=1	K=2	K=3	K=4	K=5	Średnia [s]	K=1	K=2	K=3	K=4	K=5	Średnia [s]
Liczba klientów	20	6,77	0,49	0,37	0,24	0,18	4,68	6,25	0,29	0,22	0,27	0,24	1,45
	25	2,71	0,71	0,72	0,54	0,55	5,04	4,57	0,37	0,56	0,34	0,49	1,27
	30	1,33	4,56	0,76	0,71	0,89	6,37	1,85	0,83	0,93	1,26	0,66	1,11
	35	9,80	2,40	2,02	1,07	1,37	8,61	21,22	3,33	1,81	1,31	2,01	5,94
	40	6,67	30,90	14,51	2,49	1,94	16,09	4,16	3,53	3,55	2,27	6,32	3,97
	45	-	51,54	3,83	3,57	3,59	21,51	-	6,22	6,94	7,10	3,72	5,99
	50	-	55,15	39,77	55,42	4,51	40,97	-	165,95	55,44	54,94	5,00	70,33
	55	-	133,60	143,79	8,91	65,36	81,33	-	76,18	63,57	8,14	8,05	38,98
	60	-	82,93	84,83	9,12	8,90	49,15	-	43,29	18,03	8,20	12,39	20,47
	65	-	19,13	17,66	95,87	52,44	50,02	-	276,98	91,99	62,22	11,16	110,59
	70	-	199,97	19,74	128,57	17,57	87,17	-	300,05	21,92	144,94	129,08	149,00
	75	-	-	156,31	156,79	14,08	100,54	-	-	167,60	153,45	158,22	159,76
80	-	-	300,02	172,38	156,45	177,21	-	-	287,25	172,23	152,41	203,96	
		Średnia					49,90	Średnia					59,45

Źródło: opracowanie własne.

Główna różnica pomiędzy zaprezentowanymi modelami matematycznymi, to założenie o liczbie możliwych tras występujących w rozwiązaniu. W pierwszym modelu informacja o liczbie tras w rozwiązaniu jest z góry znana: $K^* = K$. W drugim liczba utworzonych tras jest zmienną decyzyjną i zachodzi zależność: $K^* \leq K$. W tabeli 5-8 przedstawiono czas optymalizacji poszczególnych przypadków zbiorów klientów dla obu modeli oraz dla zakładanej liczby tras. Do około 45 klientów różnica pomiędzy oboma modelami nie jest specjalnie widoczna. Powyżej tej wartości model (*nVRP1*), w metodzie optymalizacji dokładnej, wykazuje się szybszym czasem zbieżności. W ogólnym porównaniu średnich czasów optymalizacji wszystkich przypadków testowych, model (*nVRP1*) był rozwiązywany o ponad 19% krócej niż model(*nVRP2*). Jest to spowodowane występowaniem dodatkowej zmiennej, czyli liczby tras uzyskanych w rozwiązaniu. Pomimo wydłużenia czasu obliczeń, dodatkowy warunek posiada pozytywny aspekt - przy zbyt dużej wartości K występuje możliwość zredukowania liczba tras w rozwiązaniu. Efekty takiego działania przedstawiono w tabeli 5-9, gdzie zaprezentowano jaka średnia liczba tras została wyznaczona dla wszystkich przykładów sformułowanych zgodnie z modelem (*nVRP2*).

³⁶ Charakterystyka popytu i podaży w tych przykładach nie ma istotnego wpływu na czas optymalizacji, ponieważ wielkość towarów jest zdecydowanie mniejsza niż dostępna pojemność pojazdów (charakterystyka dystrybucji drobnicowej przedstawiono w rozdziale 4).


Tabela 5-9 Średnia liczba tras K^* uzyskanych przy rozwiązaniu modelu ($nVRP2$) dla analizowanych przykładów.

Liczba pojazdów K :	Liczba klientów n :												
	20	25	30	35	40	45	50	55	60	65	70	75	80
1	1,00	1,00	1,00	1,00	1,00	-	-	-	-	-	-	-	-
2	2,00	2,00	2,00	1,50	2,00	2,00	2,00	2,00	2,00	2,00	2,00	-	-
3	2,00	1,83	3,00	2,00	2,83	3,00	2,83	2,83	3,00	3,00	3,00	3,00	3,00
4	1,83	2,83	2,33	3,50	2,83	3,17	3,83	4,00	4,00	4,00	3,50	4,00	3,50
5	2,00	2,33	2,67	2,67	2,50	3,83	4,17	3,83	4,67	4,00	4,50	4,50	4,00

Źródło: opracowanie własne.


Przyjmowanie z góry, że dany zbiór klientów ma być obsłużony przez konkretną liczbą pojazdów (ma zostać utworzona znana liczba tras) może prowadzić do uzyskiwania rozwiązania nie najkorzystniejszego. Dzięki zastosowaniu modelu ($nVRP2$) możliwe jest odnalezienie rozwiązania, w którym zostało wyznaczonych mniej tras, a co za tym idzie, o mniejszym koszcie dla firmy transportowej. Oczywiście wybór właściwego modelu zależy od specyfiki firmy transportowej jak również warunków posiadanych zasobów technicznych i ludzkich.

Drugim czynnikiem wpływającym na poziom złożoności problemu jest specyfika okien czasowych klientów. Jak już wspomniano zbadano dwie wersje występowania okien: pierwsza, wszyscy klienci mają przypisane indywidualne okna (na wykresach: "okna - wszyscy") oraz druga, tylko część klientów ma przypisane okna czasowe obsługi (na wykresach: "okna - mieszane"). Analizę wpływu zaprezentowano na rysunku 5.18 oraz rysunku 5.19 dla odpowiednio modelu ($nVRP1$) oraz ($nVRP2$).



Rysunek 5.18 Średni czas optymalizacji dla modelu ($nVRP1$) w zależności od struktury okien czasowych u klientów.

Źródło: opracowanie własne.



Rysunek 5.19 Średni czas optymalizacji dla modelu (nVRP2) w zależności od struktury okien czasowych u klientów.

Źródło: opracowanie własne.

W obu wersjach modelu występowanie klientów bez sprecyzowanego okna czasowego skraca czas optymalizacji. W przypadku pierwszego modelu algorytm potrzebował średnio aż o 73% mniej czasu na odnalezienie rozwiązania. W drugim modelu, średnia redukcja wyniosła 53% w stosunku do wersji gdzie wszyscy klienci mają przypisane okna. Otrzymane wyniki są dość oczywiste, ponieważ wprowadzenie okien czasowych w problemach VRP powoduje, że stają się one bardziej algorytmicznie niedostępne. Im więcej jest klientów z oknami czasowymi i im zbiór klientów jest większym, tym proces poszukiwania rozwiązania się wydłuża.

Podsumowując powyższe analizy, jeśli poprzez użyteczność metody optymalizacyjnej modelu przyjmie się 5 minut obliczeń, to rozwiązując przedstawione modele można zaobserwować następujące cechy³⁷:

- Oba modele wykazują swoją przeciętną użyteczność do 40 klientów dla jednej trasy,
- Wprowadzenie liczby tras w rozwiązaniu jako zmienna powoduje, że czas optymalizacji zwiększa się średnio o 26%. Dotyczy to przypadków powyżej 45 klientów,
- Dla przypadków poniżej 45 klientów model (nVRP2) wykazuje szybszą zbieżność, jednak wartość różnicy to zaledwie kilka sekund,
- Zwiększanie liczby potencjalnych tras w rozwiązaniu znacząco obniża czas obliczeń,
- Zbiory klientów, których specyfikacja okien czasowych jest zróżnicowana, istotnie wpływają na czas optymalizacji - redukcja o co najmniej 50% w obu modelach,
- W zależności od struktury okien czasowych oba modele wykazują maksymalną użyteczność stosowania do około 80 klientów.

Nawiązując do informacji otrzymanych z wywiadu (w danym rejonie obsługi zazwyczaj występuje od 40 do 60 klientów) można zakładać, że zaprezentowane założenia, modele i sposoby ich rozwiązywania są możliwe do zastosowania w rzeczywistej dystrybucji towarów w mieście. Zwiększenie użyteczności modeli wiąże się z zastosowaniem metod przybliżonych, których cechą charakterystyczną jest uzyskiwanie dobrej jakości rozwiązań dopuszczalnych w znacznie krótszym czasie obliczeń. Z uwagi, że nie jest to celem pracy, dalsze analizy zostały wykonane w oparciu o powyższe założenia. Dodatkowo zastosowanie metod

³⁷ Są to wnioski dla metody dokładnej rozwiązywania problemów VRP.

dokładnych eliminuje wpływ błędu metody optymalizacyjnej na jakość otrzymanego rozwiązania. Przy porównywaniu wyników w innych podejściach ma to kluczowe znaczenie.

5.4 WNIOSKU Z ROZDZIAŁU NR 5

Jest dość oczywistym, że jakość otrzymanych wyników z eksperymentów obliczeniowych jest ściśle zależna od jakości używanych danych. Danymi podstawowymi w zagadnieniach przewozu jest czas przejazdu przez poszczególne odcinki sieci drogowej. W pracy informacje te uzyskano dzięki symulatorowi mikroskopowemu ruchu drogowego. Model mikroskopowy wybranego obszaru miasta Krakowa został skalibrowany z rzeczywistymi, przekrojowymi pomiarami ruchu drogowego, dzięki czemu uzyskano statystyczną zgodność modelu. Procedurę modelowania zaprezentowano w pierwszej części rozdziału. Należy jednak zwrócić uwagę na fakt, że dane otrzymane w wyniku przeprowadzonych symulacji są danymi losowymi, posiadającymi cechy ruchu rzeczywistego. Takimi cechami są m.in. zachowanie rzeczywistej propagacji wartości czasu przejazdu na sąsiadujących odcinkach drogowych, czy też uwzględnienie rzeczywistego występowania miejscowych zatorów. Jednakże dzięki zachowaniu wysokiego poziomu szczegółowości procesu modelowania oraz przyjętych założeń mikroskopowych można przyjąć, że otrzymane dane posiadają wystarczającą reprezentatywność do przeprowadzania badań nad przyjętymi modelami.

W rozdziale przedstawiono również charakterystyki kluczowych modeli dla problemów R-SPP oraz VRP-STW, które są elementem proponowanego podejścia modelowania niepewności wartości parametrów. Wykonane badania wykazały użyteczność stosowania proponowanego podejścia w rzeczywistym procesie planowania dystrybucji towarów na terenach miejskich. Przyjmując założenia wynikające z charakterystyki rzeczywistego procesu rozwożenia towarów w miastach (głównie podział na rejony obsługi), proponowane podejście umożliwia rozwiązywanie problemów do średnio 60 klientów do 5 minut (w specyficznych przypadkach maksymalnie 80 klientów). Natomiast problem R-SPP wykazuje się użytecznością stosowania do sieci składających się z około 500 wierzchołków - wtedy czas optymalizacji jest mniejszy niż 1 sekunda. Dla większych sieci wzrost czasu obliczeń ma charakter wykładniczy. Dodatkowo zbadano wpływ wartości poszczególnych wag na jakość uzyskiwanego rozwiązania. Na podstawie serii testów wykazano, że zaproponowany wektor wag Ω_1^* oraz Ω_2^* utworzony na podstawie wywiadu z firmą transportową charakteryzuje się dobrym kompromisowym rozwiązaniem, a położenie jego w przestrzeni rozwiązań dopuszczalnych jest niedalekie od rozwiązania idealnego.

6 ANALIZA METODYKI INTEGRACJI PROBLEMU NAJKRÓTSZEJ ŚCIEŻKI R-SPP Z ZAGADNIENIEM WYZNACZANIA TRAS POJAZDÓW VRP-STW

W poprzednich podrozdziałach zostały przedstawione charakterystyki obu ważnych elementów zaproponowanego podejścia do problemów wyznaczania tras pojazdów w warunkach niepewności - model R-SPP oraz dwie wersje modeli VRP. Kolejnym etapem badań jest określenie: czy zaprezentowane podejście typu "robust" różni się od powszechnie znanych i funkcjonujących podejść oraz jeśli różnica występuje, to jakie posiada cechy. Aby odpowiedzieć na postawione pytania wykonano serię testów. Poniżej przedstawiono opis wykonanych symulacji i uzyskane wyniki.

W przeprowadzonych analizach sprawdzono jakość uzyskanych rozwiązań dla trzech wariantów:

1. Wariant deterministyczny,
2. Wariant stochastyczny,
3. Wariant odpornościowy.

W celu zachowania porównywalności proponowanej metody uwzględniania niepewności danych, w pierwszych dwóch wariantach założono taki sam mechanizm uproszczenia sieci drogowej do grafu zastępczego. Struktura problemu, liczba kryteriów cząstkowych, normalizacja funkcji kryterialnej oraz wszystkie inne założenia modelowania problemu VRP została przeniesiona na grunt optymalizacji deterministycznej oraz stochastycznej. Różnica polega na sposobie interpretacji danych wejściowych do budowy modelu. W wersji deterministycznej w pierwszym etapie obliczono deterministyczne najkrótsze ścieżki. Jest to sytuacja, gdy wartość parametru konserwatywności w modelu (RC_{SPP}^e) wynosi $\Gamma = 0$, a więc parametrami modelu są m.in. wartości przeciętne czasu przejazdu na poszczególnych odcinkach. Następnie, na podstawie otrzymanych wyników wykonano marszrutyzację pojazdów. Tak, więc wariant deterministyczny polegał na obliczeniu deterministycznych najkrótszych ścieżek wykorzystując model (RC_{SPP}^e) i założeniem, że $\Gamma = 0$, a następnie wykorzystanie modelu ($nVRP1$) lub ($nVRP2$).

W wariantach stochastycznych do obliczenia stochastycznych ścieżek pomiędzy klientami wykorzystano model α -najkrótszej ścieżki (na podstawie prac [61, 95]). Przyjęto, że modelowanie niepewności czasu przejazdu w sieci drogowej jest opisane przez rozkłady prawdopodobieństwa i zakłada się, że jest możliwe przejście od stochastycznego opisu czasu przejazdu do deterministycznego odpowiednika przy pomocy odwrotności dystrybucji tych rozkładów prawdopodobieństwa. Takie założenie pozwala uprościć optymalizację stochastyczną do deterministycznej. Model α -najkrótszej ścieżki jest oparty o teorię programowania z zadanymi prawdopodobieństwami realizacji ograniczeń (ang. Chance Constrained Programming). Zakłada się w nim, że dane ograniczenie modelu w optymalizacji jest zachowane z pewnym prawdopodobieństwem $1 - \alpha$. Wartość tego prawdopodobieństwa określa parametr α , który

można utożsamiać z poziomem ufności. Przyjęto, że losowość jest opisana rozkładem normalnym. Parametrami modelu są: prawdopodobieństwo $1 - \alpha$, wartość oczekiwana oraz odchylenie standardowe czasu przejazdu. Na podstawie tych parametrów jest obliczana wartość czasu przejazdu. Symulację wariantu stochastycznego wykonano dla poziomów prawdopodobieństwa: $1 - \alpha = 0,65$, $1 - \alpha = 0,80$ oraz $1 - \alpha = 0,95$. Wartości oczekiwane oraz odchylenia standardowe czasu przejazdu na poszczególnych odcinkach drogowych przyjęto dokładnie o takich samych wartościach jak w wariancie odpornościowym. Charakterystyki te zostały wyznaczone osobno dla interwału czasowego, który dzieli porę dnia na równe części (zgodnie założeniami modeli z podrozdziału 4.1.1). Interwał zmiany to jedna godzina, czyli zbiór interwałów będzie mieć indeksy: $T = \{1, \dots, 12\}$. Innymi słowy, indywidualny opis zmienności czasu przejazdu na odcinkach sieci przy poziomie prawdopodobieństwa 95% jest opisany rozkładem normalnym z parametrami średniego czasu przejazdu i odchylenia standardowego dla jednej godziny. Analogicznie jak w wariancie deterministycznym i odpornościowym, na podstawie otrzymanych stochastycznych, najkrótszych ścieżek dokonano obliczenia problemu wyznaczania tras pojazdów dla obu modeli VRP.

Wariant odpornościowy to proponowane w pracy podejście uwzględniania niepewności czasu przejazdu. W analizie wykorzystano dane uzyskane z symulatora Aimsun 8.1 Nieokreśloność wartości czasu przejazdu na poszczególnych odcinkach drogowych została opisana w postaci zbioru niepewności (założenie z podrozdziału 4.1.2), zdefiniowanego przez wartość oczekiwaną i odchylenie standardowe dla każdej godziny mikroskopowej symulacji z zakresu godzin pracy magazynu. Wartość oczekiwana w tym wypadku oznacza średni czas jaki jest potrzebny aby pokonać dany odcinek w warunkach symulacji ruchu drogowego. Symulacje obliczeniowe w wariancie odpornościowym zostały wykonane z trzema poziomami konserwatywności:

- Niskim: $\Gamma = 5$ (dalej "Gamma 5"),
- Średnim: $\Gamma = 20$ (dalej "Gamma 20"),
- Maksymalnym: $\Gamma = |VP| + |C|$ (dalej "Gamma maks").

Analizy wykonano na losowych zbiorach klientów opisanych w poprzednim podrozdziale. Podobnie, uwzględniono dwie struktury okien czasowych: pierwsza wszyscy mają przypisane okno obsługi; drugie od 30% do 50% klientów nie ma sprecyzowanego okna. Okna czasowe są symetryczne, typu elastycznego o szerokości 3 godzin (sztywne okno czasowe jest szerokości 2 godziny). Charakterystyka popytu i podaży na towary została wygenerowana losowo zgodnie z opisem charakteryzującym dystrybucję drobnicową w mieście (rozdział 4). Magazyn dysponuje maksymalnie 5 pojazdami o ładowności 1000 kg. Magazyn jest przypisany do wierzchołka: $vp = \{1\}$, a lokalizację wierzchołka zaznaczono na rysunku 5.2. Czas pracy magazynu to 6:00 - 21:00.

Reasumując, zgodnie z powyższym opisem uzyskano zbiór przykładów testowych, którego liczebność wyniosła 260. Zbiór ten pełni rolę zbioru referencyjnego, który w zależności od wariantu był modyfikowany. Liczebność zmodyfikowanych zbiorów testowych wyniosła:

- Zbiór deterministyczny: 260 przykładów testowych (tożsamy ze zbiorem referencyjnym),

- Zbiór stochastyczny: 780 przykładów (przykłady testowe referencyjne z prawdopodobieństwami wystąpienia czasu przejazdu: $1 - \alpha = 65\%$, $1 - \alpha = 80\%$ oraz $1 - \alpha = 95\%$),
- Zbiór odporny na wahania: 780 przykładów (260 przykładów testowych referencyjnych zwielokrotnione 3-krotnie przez różne poziomy konserwatywności I).

Zgodnie z opisem wcześniejszym, każdy z przykładów testowych ze wszystkich zbiorów danych został rozwiązany metodą dokładną, którą oferuje pakiet optymalizacyjny CPLEX 12.5. Implementacja modeli została wykonana w programie MATLAB przy pomocy zestawu narzędzi ROME 1.09. Sposób rozwiązania rozważanych podejść (deterministyczny, stochastyczny, odpornościowy) zostały oparte o metodykę przedstawioną w podrozdziale 4.2 oraz na rysunku 4.5.

6.1 METODA PORÓWNYWANIA ROZWIĄZAŃ

6.1.1 PARAMETRY OCENY ROZWIĄZAŃ

Zaproponowana w poprzednim rozdziale funkcja kryterialna składa się, w pełnej wersji, z pięciu kryteriów cząstkowych, więc wydają się być dość naturalne, że zmienność tych parametrów będzie badana. Uściślając, każde rozwiązanie ze wszystkich wariantów będzie oceniane przez parametry oceniające:

1. **Czas przejazdu** - jest to suma czasów wszystkich tras w danym rozwiązaniu, określający tylko i wyłącznie czas poruszania się pojazdów w sieci drogowej; wyrażony w minutach,
2. **Dystans** - jest to suma długości poszczególnych tras z danego rozwiązania; wyrażony w kilometrach,
3. **Czas wczesnego przyjazdu** - jest to suma wszystkich czasów zbyt wczesnego przyjazdu kierowcy do poszczególnych klientów liczony w odniesieniu do sztywnego okna czasowego; wyrażony z minutach,
4. **Czas opóźnienia** - jest to suma wszystkich czasów zbyt późnego przyjazdu kierowcy do poszczególnych klientów liczony w odniesieniu do sztywnego okna czasowego; wyrażony z minutach,
5. **Liczba tras** - jest to liczba tras otrzymanych w wyniku procesu optymalizacji,
6. **Liczba wczesnych przyjazdów** - określa liczbę klientów, u których obsługa transportowa rozpoczęła się zbyt wcześnie (w odniesieniu do sztywnych okien czasowych),
7. **Liczba opóźnień** - określa liczbę klientów, u których obsługa transportowa rozpoczęła się zbyt późno (w odniesieniu do sztywnych okien czasowych),
8. **Czas optymalizacji** - czas potrzebny na otrzymanie rozwiązania w problemie wyznaczania tras pojazdów; wyrażony w sekundach,
9. **Łączny czas optymalizacji** - czas optymalizacji plus czas potrzebny na przygotowanie danych poprzez zagadnienie najkrótszej ścieżki (w wersji adekwatnej); wyrażony w sekundach.

6.1.2 SCHEMAT PORÓWNYWANIA ROZWIĄZAŃ

Źródłem informacji potrzebnych do wykonania planu przewozów towarów w mieście jest ruch drogowy i związany z nim czas przejazdu. Jak to już przedstawiano w rozdziale 2, ruch

drogowy charakteryzuje się wysokim dynamizmem i losowością. Stąd porównywanie otrzymanych rozwiązań z poszczególnymi wariantów na podstawie danych wejściowych może być niewłaściwe. Jest to związane z tym, że pomimo uwzględnienia niepewności wartości czasu przejazdu w modelu, rzeczywiste wartości mogą być inne niż te założone. Aby przetestować jakość uzyskanego rozwiązania wygenerowano sześć losowych scenariuszy. Zakłada się, że losowy scenariusz jest rzeczywistą realizacją wartości czasu przejazdu, a wartości wykorzystane w optymalizacji to dane użyte w procesie planowania tras, np. dane z modułu prognostycznego. Każdy ze scenariuszy został utworzony w oparciu o charakterystykę poszczególnych odcinków drogowych sieci, w następujący sposób:

(6.1)

$$\left(\widetilde{\mathbf{T}}_{e_{org}}^{SP}\right)_r = \left\{ \left[\bar{t}_{ij}^{SP}(\tau_{e_{org}}) + \varepsilon_r \cdot \delta_{ij}^{SP}(\tau_{e_{org}}) \right], \delta_{ij}^{SP}(\tau_{e_{org}}) \sim N\left(\hat{t}_{ij}^{SP}(\tau_{e_{org}}), \hat{t}_{ij}^{SP}(\tau_{e_{org}})\right), \forall(i, j) \right. \\ \left. \in \mathbf{AS} \wedge r = 1, \dots, 6, \exists \tau_{e_{org}} \in \mathbf{T}: e_{org} \in (U_{\tau-1}, U_{\tau}) \right\}$$

Gdzie:

$\delta_{ij}^{SP}(\tau_{e_{org}})$ - jest zmienną losową o rozkładzie normalnym zdefiniowanym średnią czasu przejazdu $\bar{t}_{ij}^{SP}(\tau_{e_{org}})$ oraz odchyleniem standardowym $\hat{t}_{ij}^{SP}(\tau_{e_{org}})$ dla każdego łuku (i, j) zależnej od interwału czasowego $\tau_{e_{org}}$ wyznaczonego przez początek okna czasowego e_{org} wierzchołka źródłowego org ,

ε_r - jest losową wartością z rozkładu równomiernego opisującą stopień realizacji niepewności dla scenariusza $r = 1, 2, \dots, 6$. Stopień realizacji niepewności może przyjmować wartości z zakresu:

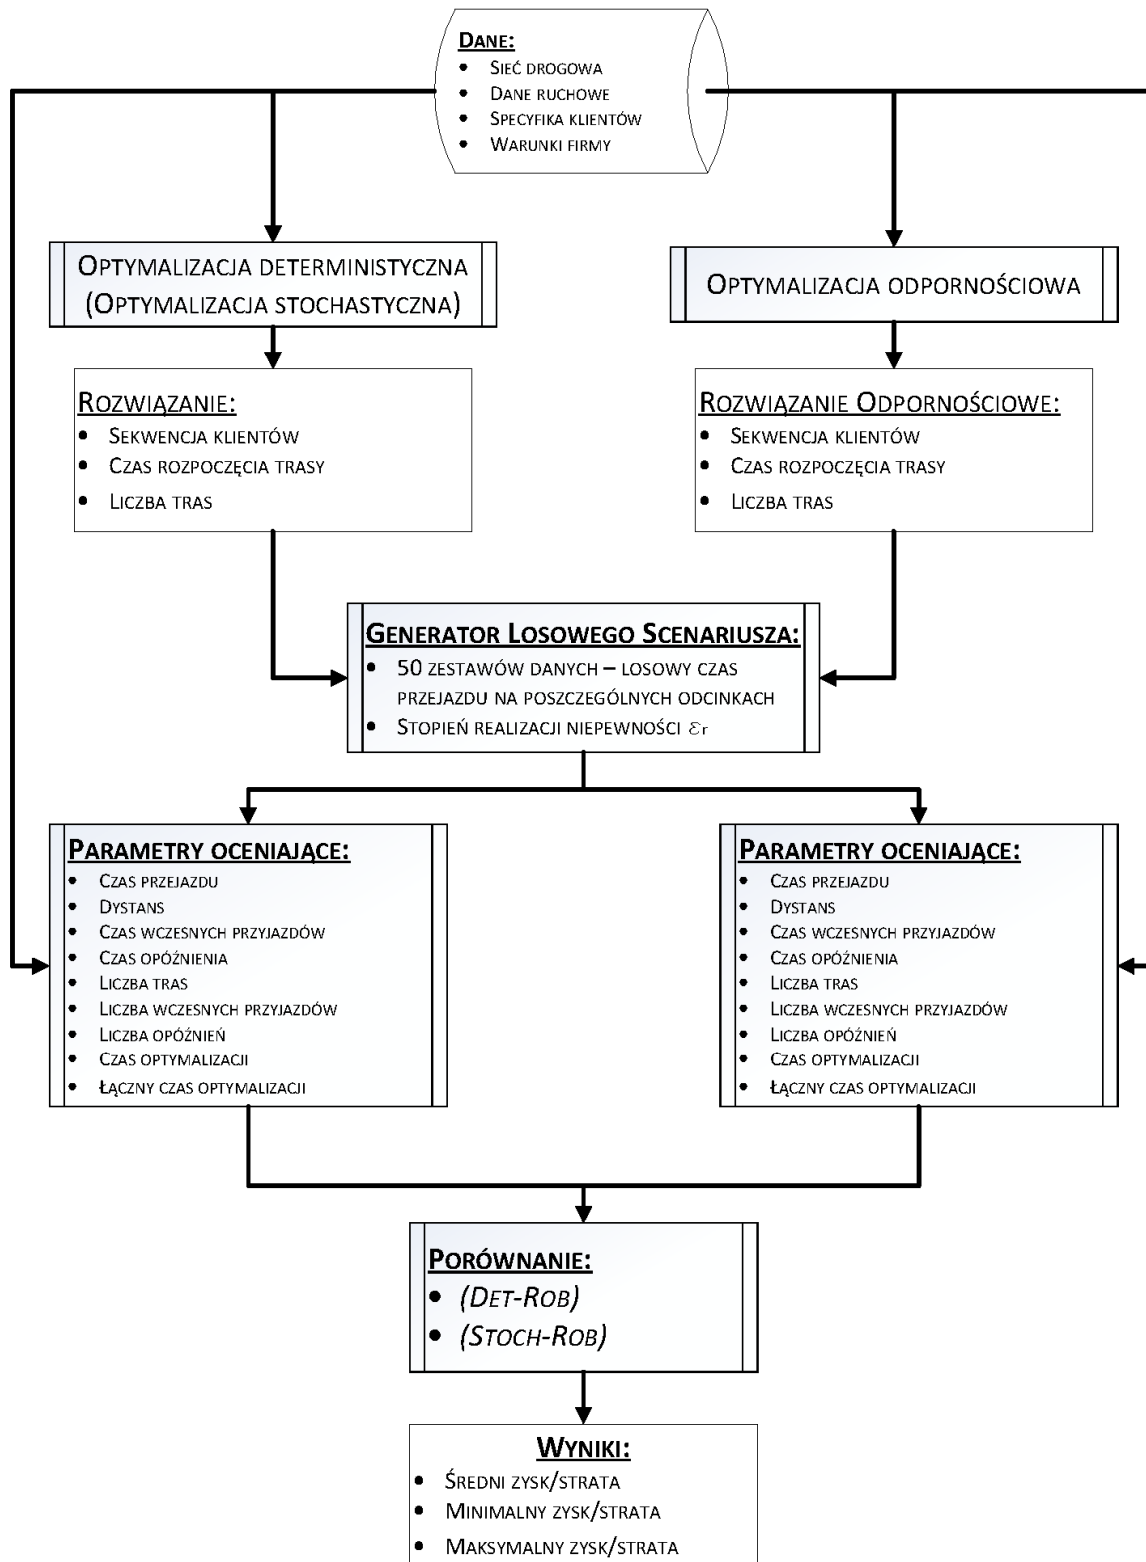
- $\varepsilon_1 \in [0; 0,2]$ - dalej "Scenariusz 20%",
- $\varepsilon_2 \in [0,2; 0,5]$ - dalej "Scenariusz 50%",
- $\varepsilon_3 \in [0,4; 0,8]$ - dalej "Scenariusz 80%",
- $\varepsilon_4 \in [0,6; 1,0]$ - dalej "Scenariusz 100%",
- $\varepsilon_5 \in [0,8; 1,2]$ - dalej "Scenariusz 120%",
- $\varepsilon_6 \in [0,8; 1,5]$ - dalej "Scenariusz 150%",

Pierwsze dwa scenariusze można interpretować jako, sytuację gdy rzeczywista realizacja niepewności znacznie różni się od założeń np. nie trafiona prognoza warunków ruchowych. Kolejne dwie, to przypadki gdzie błąd prognozy jest zmniejszany, jednak nadal założone wartości danych były większe niż ich rzeczywista realizacja (pesymizm planisty transportu). Ostatnie dwa scenariusze to sytuacje, gdy część danych rzeczywistych przekracza prognozę. W "Scenariusz 150%" losowa część danych (a dokładnie odchylenie standardowe czasu przejazdu) jest zwiększona nawet o połowę, co może nawiązywać do incydentów nietypowych w sieci drogowej. Rzeczywista realizacja czasu przejazdu losowo przekracza założoną zmienność parametrów modelu. Wariant ten ma na celu sprawdzenie jak uzyskane rozwiązanie sprawdza się w warunkach nieprzewidywanych.

Taka konstrukcja generowania losowych scenariuszy posiada dwie cechy: możliwość sterowania poziomem występujących losowych perturbacji oraz wybór losowo wybranych war-

tości zgodnie z indywidualną zmiennością każdego z odcinków sieci drogowej. O scenariuszach, w których parametr stopnia realizacji niepewności jest mniejszy niż 100%, można mówić że są typowymi scenariuszami, w których nie dzieją się wyjątkowe sytuacje ruchowe. Im stopień realizacji niepewności jest większy, tym w danym scenariuszu występuje więcej odcinków w sieci drogowej, na których występują zjawiska nietypowe np. incydenty drogowe, zwiększające czas przejazdu.

Na podstawie tak przygotowanych danych obliczono wartości parametrów oceniających jakość każdego rozwiązania we wszystkich wariantach i typach danych (dla każdego zbioru danych). Z uwagi na fakt, że wartości ε_r były generowane losowo, dla każdego scenariusza stopień realizacji niepewności utworzono po 50 losowych zestawów danych. Oznacza to, że w ramach losowego scenariusza każde rozwiązanie zostało poddane 50-krotnej weryfikacji. Takie postępowanie ma na celu symulację potencjalnych losowych zmian w ruchu drogowym w odniesieniu do danych wykorzystanych do planowania tras. Porównania wyników dokonano przez obliczenie różnicy pomiędzy wartościami parametrów oceniających: wersji deterministycznej z odpornością oraz wersji stochastycznej z odpornością. Wspomniane różnice zostały obliczone dla wszystkich 50 losowych zestawów danych, a ich cechy zostały zaprezentowane poprzez: wartość średnią, wartość minimalną oraz wartość maksymalną. Zaprezentowany opis postępowania przy porównywaniu wariantów został zaprezentowany na rysunku poniżej (rysunek 6.1).



Rysunek 6.1 Ogólny schemat porównywania jakości wariantów deterministycznego, stochastycznego z odpornościowym.

Źródło: opracowanie własne.

Powyższy schemat jest jednocześnie poglądowym przepływem danych pomiędzy funkcjami napisanymi przez autora tej pracy. Działanie tych funkcji zostało oparte o funkcjonalności programu MATLAB.

Proces porównania został wykonany przez obliczenie: różnicy pomiędzy wartościami parametrów oceniających dla porównywanych wariantów oraz redukcji wartości dla wybranych parametrów oceniających. I tak, przy porównywaniu wariantu deterministycznego z odpornym na wahania ($DET - ROB$) obliczono:

$$(DIFF1)_i = F_i^{DET} - F_i^{ROB} \quad (6.2)$$

$$(RED1)_i = \frac{F_i^{DET} - F_i^{ROB}}{F_i^{DET}}$$

Analogicznie porównano warianty stochastyczne z wariantem odpornym na wahania ($STOCH - ROB$):

$$(DIFF2)_i = F_i^{STOCH} - F_i^{ROB} \quad (6.3)$$

$$(RED2)_i = \frac{F_i^{STOCH} - F_i^{ROB}}{F_i^{STOCH}}$$

F_i^{DET} , F_i^{STOCH} oraz F_i^{ROB} oznaczają wartości dla i -tego parametru oceniającego, odpowiednio, wariant deterministyczny, stochastyczny oraz odpornościowy. Jeżeli wartość różnicy jest mniejsza niż zero, oznaczać to będzie przewagę podejścia deterministycznego lub stochastycznego nad podejściem odpornościowym w kontekście, dane parametru oceniającego. Innymi słowy, można to utożsamić z potencjalnymi stratami stosowania proponowanego podejścia. W przeciwnym przypadku można mówić o potencjalnych zyskach.

Dla zachowania czytelności otrzymanych wyników poniżej przedstawiono najistotniejszą część wyników w postaci wykresów oraz tabel³⁸. Pełny opis wyników w postaci tabeli został przedstawiony w Załączniku B do pracy. Jeśli w tabeli brakuje danych (jest wpisany myślnik), to oznacza, że w przeciągu 5 minut obliczeń nie uzyskano rozwiązania dopuszczalnego lub całkowitoliczbowego. W załączniku zaprezentowano wyniki porównywania, które uzupełniają poniższe analizy, szczególnie, jeśli chodzi o zakres zmienności danego parametru.

6.2 PORÓWNANIE WARIANTU ODPORNOŚCIOWEGO Z WARIANTEM DETERMINISTYCZNYM

6.2.1 WPLYW LICZEBNOŚCI KLIENTÓW I POZIOMU KONSERWATYZMU NA JAKOŚĆ ROZWIĄZANIA

Pierwsze badanie dotyczyło sprawdzenia jak wartość parametru konserwatyzmu I^{SP} modelu odpornego problemu VRP wpływa na różnicę pomiędzy rozwiązaniem deterministycznym, a odpornym. Do analizy wzięto wszystkie dane ze zbiorów: deterministycznego i odpornego na wahania. Zmienność wielkości różnicy pomiędzy oboma podejściami sprawdzono dla trzech wartości parametru I^{SP} w zależności od liczby klientów oraz stopnia realizacji niepewności danych modelu.

³⁸ Zaprezentowane wyniki dotyczą tylko wartości średniej dla poszczególnych ocen w obrębie zestawu 50 losowych scenariuszy.

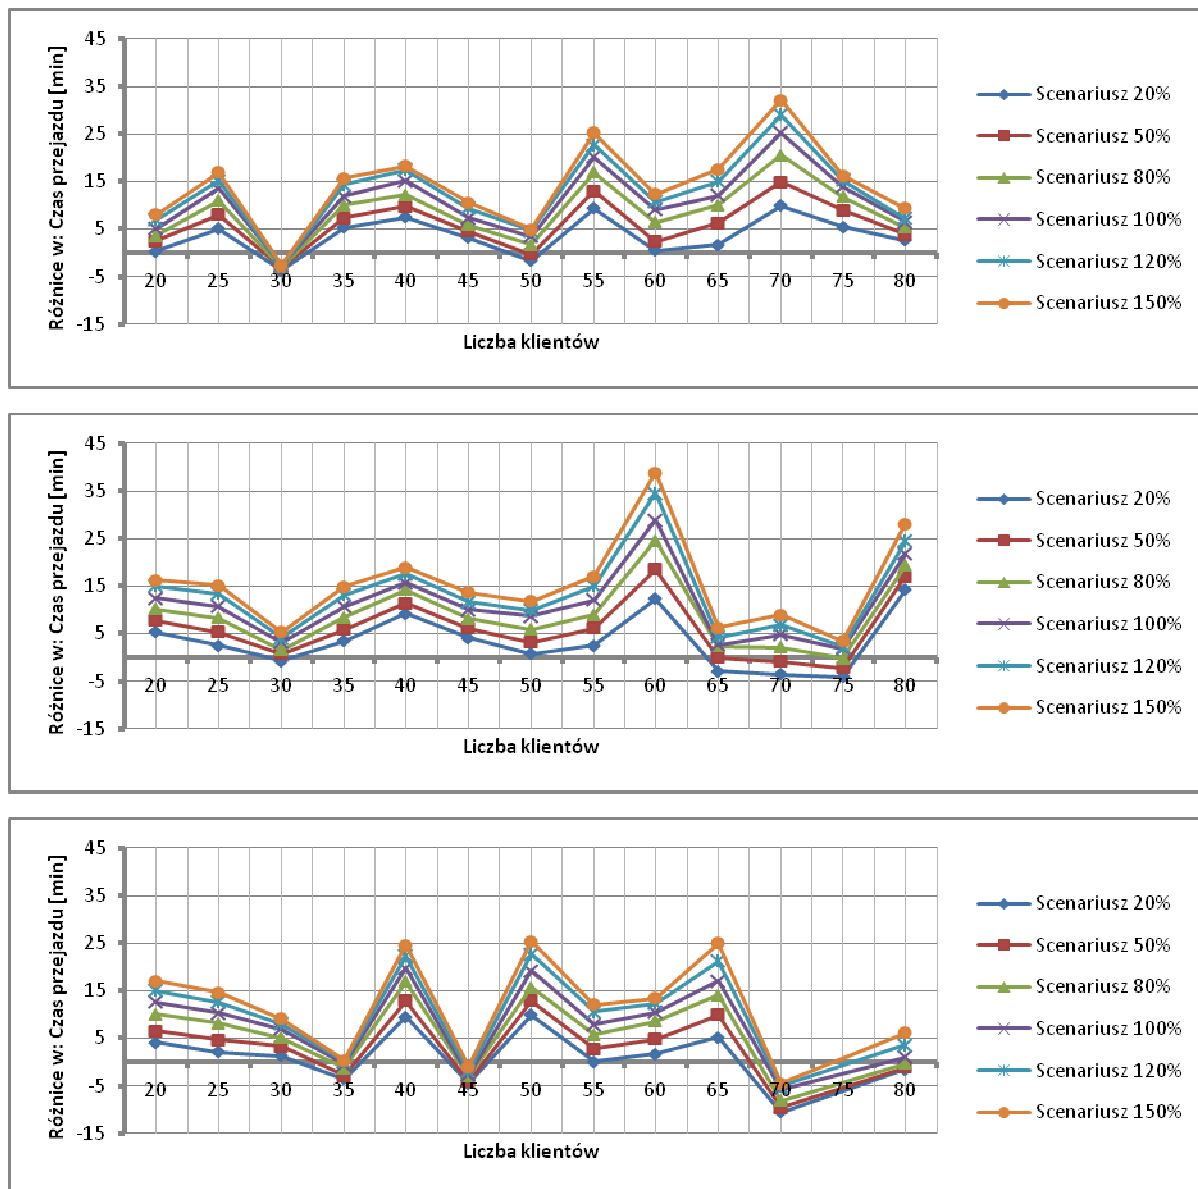
Na rysunku 6.2 przedstawiono średnie wartości czasu przejazdu. W większości przypadków liczba potencjalnych zysków jest zdecydowanie większa niż potencjalne straty w czasie przejazdu (ponad 82% przypadków). Średni zysk dla czasu przejazdu wyniósł 10,7 minuty, a zakres zmienności zawierał się od 0,1 do 38,8 minuty. Największa liczba strat w czasie przejazdu występuje przy założeniu optymalizacji typu min-max - prawie 68%, a średnia wartość straty to 3,8 minuty. Dla wszystkich poziomów parametru Γ^{SP} , największa strata czasu przejazdu wyniosła 10,1 minuty. Oznacza to więc, że potencjalne zyski w czasie przejazdu pojazdów przez sieć drogową miasta są zdecydowanie większe niż potencjalne straty. Jest to dość oczywisty wynik, ponieważ w podejściu deterministycznym nie uwzględnia się jakichkolwiek zmian parametrów modelu VRP. Stąd rozwiązanie deterministyczne wykazuje się wysoką wrażliwością na zmiany, a co za tym idzie wysokim ryzykiem poniesienia strat.

Jak już wspomniano, optymalizacja zakładająca najgorsze zmiany charakteryzuje się niesatysfakcjonującymi rezultatami. Średni, potencjalny zysk czasu przejazdu dla wszystkich scenariuszy jest znikomy, zaledwie 1,3 minuty. Oczywiście występują scenariusze gdzie wartości te są wysokie, jednak jest to jednocześnie obarczone występowaniem ryzyka straty. Zakładanie najgorszego zakresu zmian w czasie przejazdu (Gamma maks.) powoduje, że przy rzeczywistej realizacji, dane rozwiązanie charakteryzuje się zbyt dużym pesymizmem. Jest to kolejne potwierdzenie cechy takiego podejścia (w literaturze dotyczącej optymalizacji typu odpornościowego, wielokrotnie zwracano na to uwagę). Stosowanie dużych wartości parametru konserwatyzmu może mieć uzasadnienie w przypadkach gdzie: przewiduje się wysokie wahania w czasie przejazdu przez dane odcinki, w sieci drogowej, gdy wystąpią nietypowe incydenty (tymczasowe zamknięcie, roboty drogowe, tymczasowa organizacja ruchu, itp.) lub istnieje przypuszczenie, że prognoza ma duży błąd estymacji. Potwierdzeniem tego jest malejąca wartość straty np. dla liczebności 35, 45, czy 80 klientów, dla kolejnych losowych scenariuszy. Oznacza to, że im większa jest różnica między wartością założoną w modelu, a rzeczywistą wartością czasu przejazdu, tym potencjalne zyski rosną, a straty maleją.

Przyjęcie niskiego poziomu konserwatyzmu rozwiązania zmniejsza wspomniane efekty, jednak zmniejsza również potencjalne zyski w czasie przejazdu. Cechą optymalizacji typu odpornego jest zapewnienie stabilności rozwiązania nawet jak parametry modelu przekroczą założone wartości zbioru niepewności. Szczególnie można to zauważyć w Scenariuszach 120% oraz 150%, gdzie część łuków w zbiorze losowych danych ma przypisane wartości większe niż założono to w zbiorze niepewności danych modelu. Otrzymane rozwiązanie odporne na wahania jest wciąż korzystniejsze niż rozwiązanie deterministyczne. Dodatkowo można zaobserwować, że wzrost liczebności klientów nie jest skorelowany z potencjalnymi zyskami/stratami w czasie przejazdu.

Najlepsze wyniki uzyskano dla $\Gamma = 20$. Ustalenie właściwej wartości zostało dokonane przez wykonanie szeregu symulacji. W rzeczywistości może to być wykonywane przez planistę transportu lub w zaawansowanych formach przez narzędzia wspomagające podejmowanie decyzji. Optymalny poziom konserwatyzmu jest zależny od wielu czynników tj. struktura zbiorów niepewności danych, kształtu sieci drogowej, aktualnych parametrów prognozy warunków ruchowych, położenia czasoprzestrzennego klientów, czy też aktualnego stanu ruchu drogowego. Stąd dobór parametru konserwatyzmu powinien być oparty o wiedzę ekspercką.

Wiedza ta może być sformalizowana w postaci bazy reguł, która efektywnie może być wykorzystana przez programy wspomagające decyzyjne (ang. Decision Support Systems).



Rysunek 6.2 Średnia różnica pomiędzy czasem przejazdu wariantu deterministycznego a wariantu odpornego w zależności od liczby klientów oraz stopnia realizacji niepewności danych.

Wykres górny dla "Gamma 5"; wykres środkowy dla "Gamma 20"; wykres dolny dla "Gamma maks."

Źródło: opracowanie własne.

W tabeli B.2 (Złącznik B) przedstawiono również wartość redukcji czasu przejazdu w odniesieniu do rozwiązania deterministycznego. Największa redukcja jaką odnotowano to ponad 14 % zysków, przy największej stracie na poziomie 7%. Średnia redukcja dla wszystkich wariantów i przypadków to ponad 3%. Wartość redukcji maleje wraz ze wzrostem liczebności zbioru klientów, co świadczy, że wartość różnicy pomiędzy czasami przejazdu jest na mniej więcej stałym poziomie (przy większym zbiorze klientów łączny czas przejazdu wzrasta).

Kolejnym parametrem oceny jest dystans jaki został pokonany przez pojazdy w danym rozwiązaniu. W tabeli 6-1 zaprezentowano różnicę dystansu tras dla rozwiązania determi-

stycznego i odpornego na wahania oraz procentowy wzrost/spadek długości tras w odniesieniu do rozwiązania deterministycznego³⁹. Z otrzymanych danych wynika, że przy zmieniających się warunkach ruchowych korzyści wynikające ze skrócenia czasu przejazdu są ponoszone kosztem dystansu. W większości przypadków długość tras w rozwiązaniu odpornym na wahania parametrów jest większa niż w rozwiązaniu deterministycznym. Jednak średni procentowy wzrost dla analizowanych przypadków wyniósł 2,3%, a dla 30% przypadków zmiana przebiegu trasy wpływa pozytywnie na łączną długość tras. Również w przypadku tego parametru nie można wskazać korelacji wzrostu/spadku długości tras z liczebnością klientów, czy też poziomem konserwatywności rozwiązania.

Tabela 6-1 Różnica pomiędzy dystansem wariantu deterministycznego a wariantu odpornego w zależności od liczby klientów oraz wartości parametru konserwatywności oraz procentowy wzrost/spadek.

Różnica w: Dystans [m]													
Gamma =	Liczba klientów												
	20	25	30	35	40	45	50	55	60	65	70	75	80
5	-1274,6	487,9	-1270,9	1105,0	-109,2	-146,0	-1055,7	1963,1	-1468,1	-1638,7	-633,6	447,5	-2480,9
20	1031,8	252,5	707,6	134,9	-1058,1	1263,9	-1688,3	-857,3	5006,2	-3718,9	-6884,1	-3205,8	-208,4
maks.	582,8	-418,8	-1522,5	-2713,2	-1554,6	-4281,6	2899,9	-2798,2	404,1	-1218,2	-8705,1	-	-4324,6
Średnia	113,3	107,2	-695,3	-491,1	-907,3	-1054,6	52,0	-564,2	1314,1	-2191,9	-5407,6	-1379,2	-2338,0
Procentowy wzrost/spadek dystansu													
5	-1,7%	1,6%	-0,6%	2,7%	-2,3%	-2,1%	2,0%	1,1%	-0,8%	-0,7%	-0,2%	2,1%	-4,5%
20	2,7%	0,8%	-2,0%	-1,1%	-1,5%	1,5%	-2,3%	-2,2%	5,7%	-5,4%	-8,8%	-5,1%	0,7%
maks.	0,0%	-1,6%	-2,7%	-4,7%	-0,9%	-4,6%	0,5%	-1,4%	0,3%	-2,3%	-11,1%	-	-3,7%

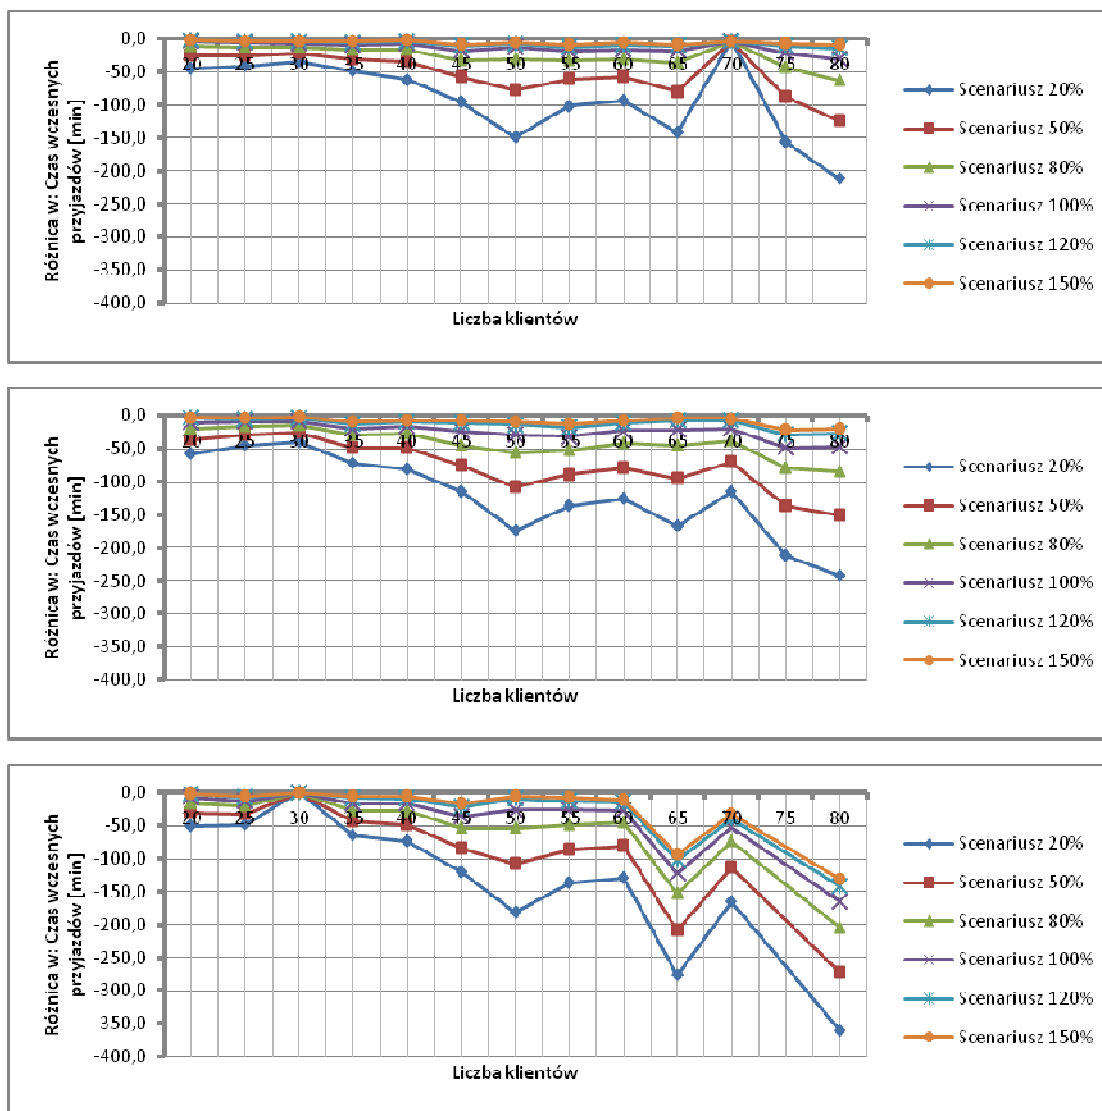
Źródło: opracowanie własne.

W procesie symulowania losowych scenariuszy oraz oceny rozwiązania założono, że czas wczesnego przyjazdu nie oznacza oczekiwania kierowcy - usługa jest wykonywana z dodatkowym kosztem. Jest to zgodne z założeniami elastycznych okien czasowych zaproponowanych w obu modelach VRP. Analogicznie późny przyjazd nie oznacza niedostarczenia przesyłki - trasa kierowcy jest kontynuowana, a koszt realizacji takiej trasy rośnie. Oprócz parametrów wczesnego i późnego czasu przyjazdu dla każdego rozwiązania obliczono również liczbę wczesnych/późnych przyjazdów do klientów. Wyniki symulacji zaprezentowano na: rysunku 6.3 i rysunku 6.5 - dla czas wczesnego/późnego przyjazdu oraz rysunku 6.4 i rysunku 6.6 - dla liczba wczesnych/późnych przyjazdów.

Rozwiązując problem VRP z przyjętymi założeniami otrzymuje się: sekwencję klientów, przypisanie klientów do trasy oraz harmonogram przyjazdów. Jeśli poszukiwanie rozwiązania zagadnienia marszrutyzacji zakłada zmienność czasu przejazdu, to musi się to odbyć kosztem planowanych czasów przyjazdów do klientów. Potwierdzeniem tej dość intuicyjnej tezy są wyniki zaprezentowane na rysunku 6.3. Dla prawie wszystkich przypadków, niezależnie od liczebności zbioru klientów i poziomu konserwatywności średni czas wcześniejszego przyjazdu jest większy niż w przypadku rozwiązania deterministycznego. Jednak wielkość różnicy jest silnie zdeterminowana od stopnia realizacji niepewności czasu przejazdu. Dla scenariuszy,

³⁹ Zależność od losowego scenariusz została pominięta, z uwagi, że odległość nie jest zmiennym parametrem modelu.

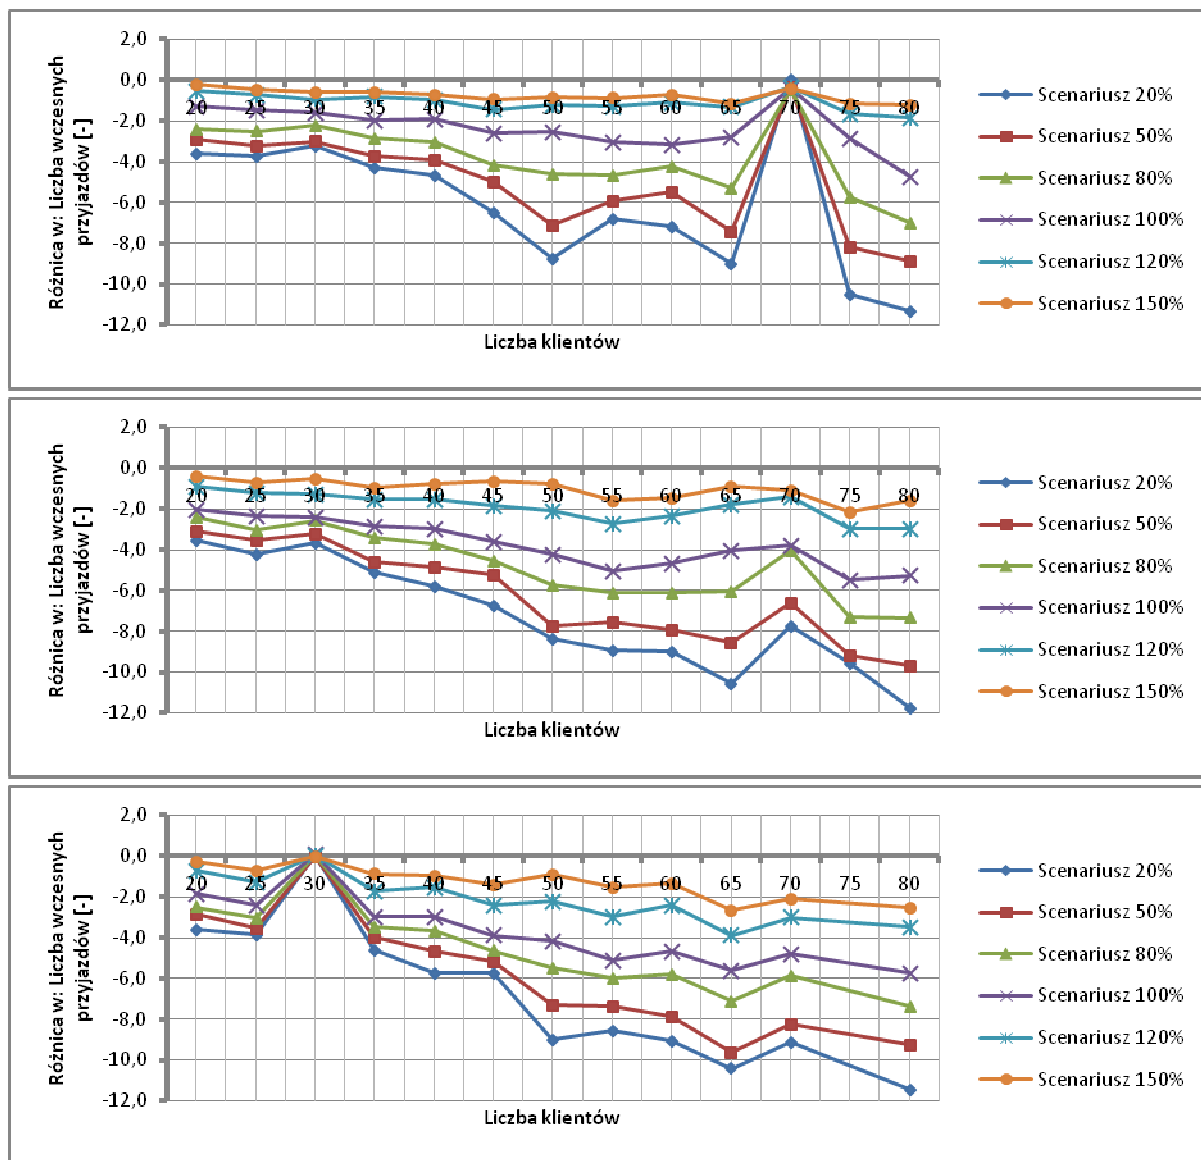
gdzie prognoza wartości czasu przejazdu będzie nazbyt pesymistyczna lub zbiór niepewności będzie zbyt szeroki, podejście odporne charakteryzuje się zdecydowanie większym czasem wczesnego przyjazdu niż w podejściu deterministycznym (Scenariusz 20%, 50% oraz 80%). Z kolei dla scenariuszy, gdzie prognoza wartości oczekiwanej i odchyłki czasu przejazdu nie posiada dużych błędów, różnica pomiędzy rozważanym parametrem jest zdecydowanie mniejsza (Scenariusze 100% oraz 120%). Dodatkowo, jeśli wyniki z rysunku 6.3 odnieść się do wyników z rysunku 6.4. można obliczyć różnicę w średnim czasie wczesnego przyjazdu na jednego klienta. W przytoczonych scenariuszach średnia różnica pomiędzy wersją deterministyczną a odporną wyniosła: 2,1 minuty dla $\Gamma = 5$, 2,5 minut dla $\Gamma = 20$ oraz 9,2 minuty dla $\Gamma = |\mathbf{VP}| + |\mathbf{C}|$. Dla pierwszych dwóch poziomów Γ , różnice na jednego klienta są tak małe, że przy warunkach rzeczywistej realizacji dystrybucji towarów, mogą być nie zauważalne. Ponadto dowiedziono, że optymalizacja najlepsza z najgorszych jest nie odpowiednim podejściem w zagadnieniach VRP. Różnice w czasie wczesnego przyjazdu oraz liczbie wczesnych przyjazdów średnio są największe.



Rysunek 6.3 Średnia różnica pomiędzy czasem wczesnego przyjazdu wariantu deterministycznego a wariantu odpornego w zależności od liczby klientów oraz stopnia realizacji niepewności danych.

Wykres górny dla "Gamma 5"; wykres środkowy dla "Gamma 20"; wykres dolny dla "Gamma maks."

Źródło: opracowanie własne.



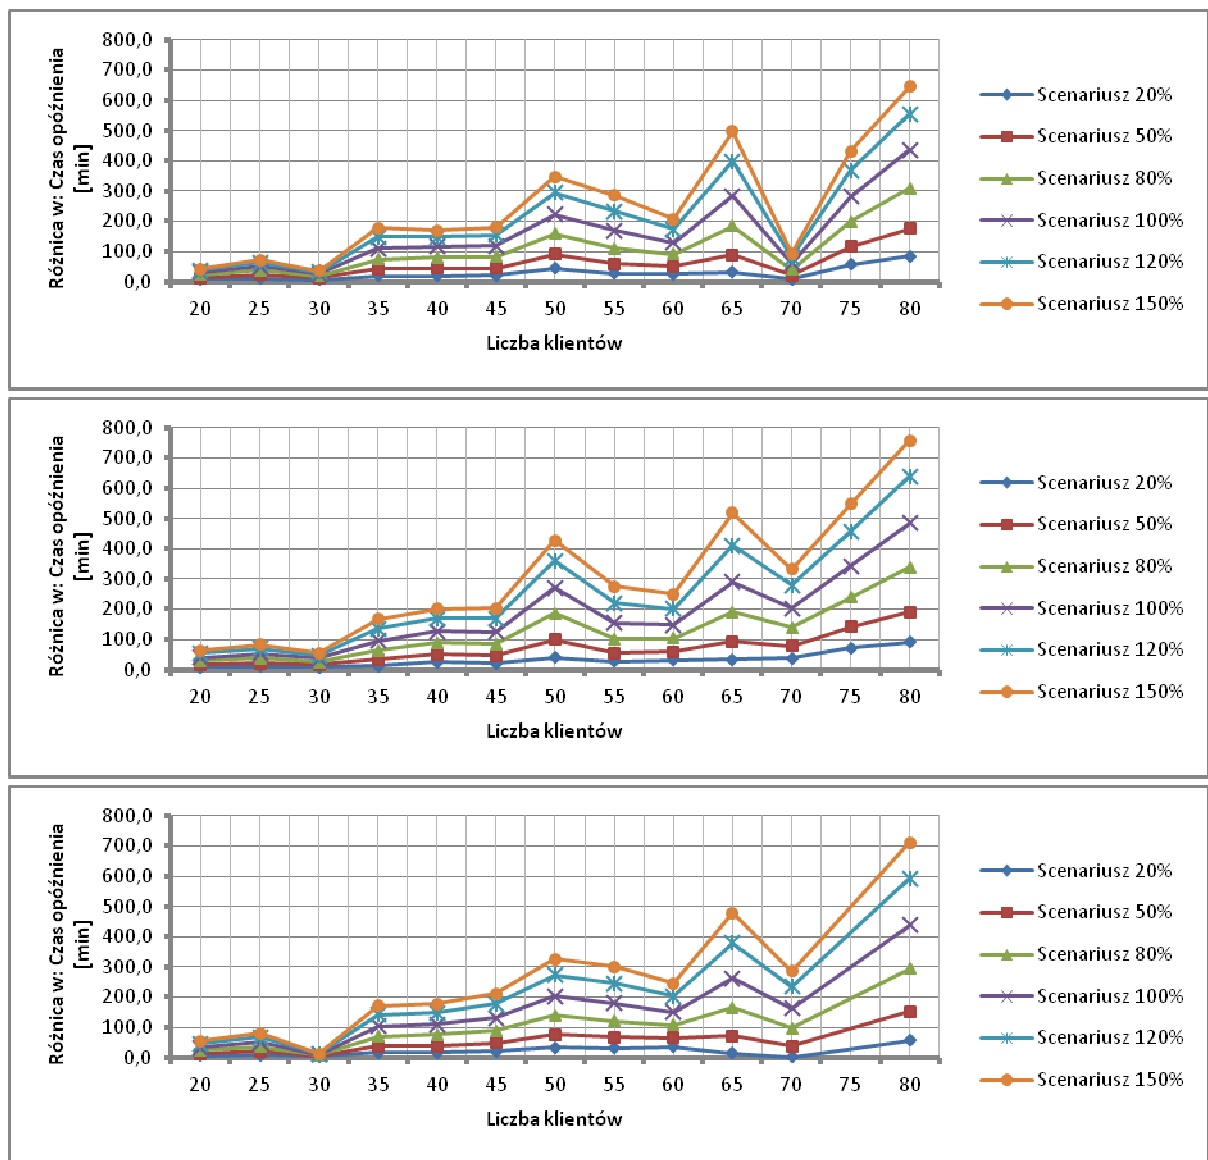
Rysunek 6.4 Średnia różnica pomiędzy liczbą wczesnych przyjazdów wariantu deterministycznego a wariantu odpornego w zależności od liczby klientów, wartości parametru konserwatywności oraz stopnia realizacji niepewności danych.

Wykres górny dla "Gamma 5"; wykres środkowy dla "Gamma 20"; wykres dolny dla "Gamma maks."

Źródło: opracowanie własne.

Czas opóźnienia to kolejny parametr oceniający uzyskane rozwiązania. W porównywalnych wariantach, wartości tego parametru są zdecydowanie na korzyść optymalizacji odpornej. Dla wszystkich analizowanych przypadków różnica jest dodatnia, co świadczy o przewadze rozwiązania typu odpornej. Co jest istotne, to różnica ta nie jest kompensacją różnicy dla parametru czasu wczesnego przyjazdu, ponieważ wartości te są wielokrotnie większe. Dla przykładu średnia różnica w czasie późnego przyjazdu przypadająca na jednego klienta dla scenariuszy 100% oraz 120% wyniosła⁴⁰: 12,7 minuty dla $\Gamma = 5$, 12,3 minuty dla $\Gamma = 20$ oraz 10,4 minuty dla $\Gamma = |VP| + |C|$. Dodatkowo można zaobserwować korelację pomiędzy potencjalnymi zyskami a liczebnością klientów - współczynnik R^2 przeciętnie wyniósł ponad 76%.

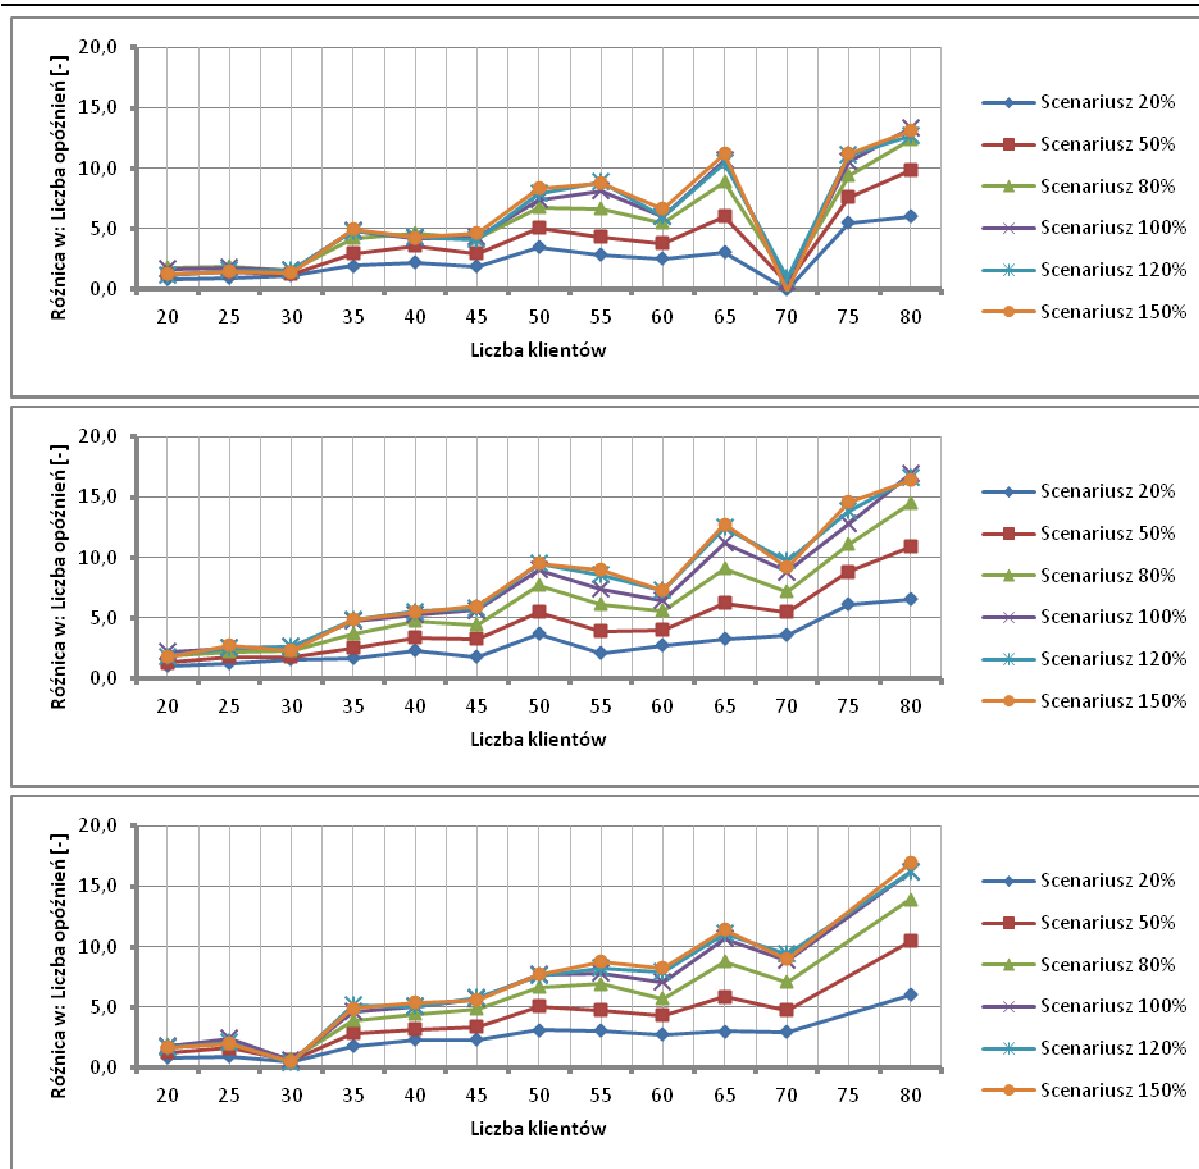
⁴⁰ Obliczono analogicznie jak w parametrze "Czas wczesnego przyjazdu".



Rysunek 6.5 Średnia różnica pomiędzy czasem opóźnienia wariantu deterministycznego a wariantu odpornego w zależności od liczby klientów oraz stopnia realizacji niepewności danych.

Wykres górny dla "Gamma 5"; wykres środkowy dla "Gamma 20"; wykres dolny dla "Gamma maks."

Źródło: opracowanie własne.



Rysunek 6.6 Średnia różnica pomiędzy liczbą opóźnień wariantu deterministycznego a wariantu odpornego w zależności od liczby klientów, wartości parametru konserwatywności oraz stopnia realizacji niepewności danych. Wykres górny dla "Gamma 5"; wykres środkowy dla "Gamma 20"; wykres dolny dla "Gamma maks."

Źródło: opracowanie własne.

Ostatnim parametrem oceniającym jakość rozwiązania jest liczba tras uzyskanych w rozwiązaniu. Rezultaty zaprezentowano w tabeli 6-2. Różnice pomiędzy poszczególnymi wariantami, są znikome - największa występuje przy porównywaniu deterministycznego z odpornościowym typu min-max, na korzyść tego pierwszego. Interpretacja takich wyników może być następująca - podejście odporne na wahania parametrów nieznacznie wpływa na liczbę tras otrzymanych w rozwiązaniu.

Tabela 6-2 Minimalna, średnia i maksymalna liczba tras w rozwiązaniu zagadnienia VRP dla podejścia deterministycznego i odpornego.

Liczba tras [-]		Liczba klientów												
		20	25	30	35	40	45	50	55	60	65	70	75	80
Deterministyczny	minimalna	1,0	1,0	1,0	1,0	1,0	2,0	2,0	2,0	2,0	2,0	2,0	3,0	3,0
	średnia	2,4	2,5	2,6	2,6	2,9	3,3	3,4	3,3	3,7	3,7	3,7	4,0	3,8
	maksymalna	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0
Gamma 5	minimalna	1,0	1,0	1,0	1,0	1,0	2,0	2,0	2,0	2,0	2,0	2,0	3,0	3,0
	średnia	2,3	2,5	2,6	2,7	2,9	3,3	3,4	3,4	3,6	3,5	3,6	3,8	3,8
	maksymalna	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0
Gamma 20	minimalna	1,0	1,0	1,0	1,0	1,0	2,0	2,0	2,0	2,0	3,0	3,0	3,0	3,0
	średnia	2,2	2,5	2,5	2,6	3,1	3,1	3,4	3,4	3,5	3,8	3,8	4,0	3,7
	maksymalna	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0
Gamma maks.	minimalna	1,0	1,0	1,0	1,0	1,0	2,0	2,0	2,0	2,0	3,0	3,0	-	3,0
	średnia	2,3	2,6	2,5	2,7	2,9	3,1	3,4	3,3	3,5	3,8	3,9	-	3,8
	maksymalna	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	-	5,0

Źródło: opracowanie własne.

Analizę czasu optymalizacji dla zaproponowanych modeli VRP przedstawiono w tabeli 6-3, w której zawarto średni czas optymalizacji oraz łączny czas optymalizacji dla prezentowanego podejścia. Pomiedzy podejściem deterministycznym a odpornościowym nie występują większe różnice, które wykazywałyby na jakiś trend. Występujące różnice wynikają ze struktury danych zagadnienia marszrutyzacji.

Na łączny czas optymalizacji składa się obliczenie najkrótszych ścieżek dla wszystkich par oraz optymalizacja problemu VRP. Oba rodzaje czasów obliczeń są silnie uzależnione od liczebności klientów. Pierwszy, jak to już opisano w podrozdziale 5.3.2, wynika z kombinatorycznego charakteru zagadnień VRP. Wielkość drugiego wynika z kwadratowego wzrostu liczby możliwych połączeń pomiędzy klientami - największa liczba możliwości równa się: $n \cdot (n - 1)$, gdzie n to liczba klientów. Odnosząc się do wyników wywiadu z firmą transportową, dla przedziału 60-80 klientów całkowity czas obliczeń zawiera się w zakresie 7 - 17 minut. Dla procesu decyzyjnego, jakim jest planowanie tras, czas ten może być akceptowalny. Szczególnie biorąc pod uwagę takie aspekty jak: obecny postęp technologiczny komputerów oraz możliwość wykonywania równoległych obliczeń na kilku stacjach roboczych jednocześnie. Warto również zwrócić uwagę, że większa część całkowitego czasu optymalizacji stanowi proces przygotowania danych, w postaci obliczenia najkrótszych ścieżek parami. Dane te mogą być wygenerowane wcześniej i mogą być przechowywane w bazie danych firmy, a przy wykonywaniu codziennych dyspozycji przez planistę, weryfikacji (aktualizacji) mogą

podlegać tylko wybrane elementy. Modyfikacja zależy od wartości prognoz czasu przejazdu w sieci drogowej oraz przyjętego poziomu uodpornienia rozwiązania przez planistę transportu.

Tabela 6-3 Czas optymalizacji oraz łączny czas optymalizacji zagadnienia VRP z zależności od liczby klientów i poziomu konserwatyzmu.

Wariant	Liczba klientów													
	20	25	30	35	40	45	50	55	60	65	70	75	80	
Czas optymalizacji [s]	Deterministyczny	1,5	1,2	1,4	4,5	8,1	10,8	54,5	63,4	29,2	60,1	86,1	132,4	206,8
	Gamma 5	0,5	1,1	2,2	30,1	22,6	12,1	48,0	48,8	43,6	88,7	113,5	188,1	178,2
	Gamma 20	0,5	1,1	2,2	18,8	3,7	12,4	34,7	48,8	45,5	126,2	169,7	185,7	286,8
	Gamma maks.	0,4	1,4	1,8	9,8	9,1	11,6	39,2	67,1	38,6	120,4	177,9	-	234,0
Łączny czas optymalizacji [s]	Deterministyczny	64,7	86,4	88,4	102,9	166,7	267,7	242,8	316,7	427,8	425,2	646,0	733,1	910,3
	Gamma 5	35,9	53,7	72,5	136,5	154,0	184,0	266,5	320,8	386,0	492,8	848,4	824,1	901,7
	Gamma 20	38,2	55,5	78,7	120,0	147,6	201,4	254,1	356,1	393,2	757,9	1037,5	801,9	964,9
	Gamma maks.	33,1	52,0	132,1	134,8	146,5	257,9	300,3	346,9	432,3	526,6	659,9	-	1011,5

Źródło: opracowanie własne.

Reasumując powyższe analizy można wyciągnąć następujące główne wnioski:


- Wysoce zmienny element systemu transportowego, jakim jest ruch drogowy determinuje stosowanie podejść, w których zakłada się zmienność i nieokreśloność parametrów modelu VRP,
- Pesymistyczne podejście zakładające maksymalną potencjalną zmianę z czasie przejazdu w sieci drogowej dla problemu VRP jest podejściem niosącym potencjalnie wysokie ryzyko ponoszenia dodatkowych kosztów. Szczególnie związanych z czasem przejazdu oraz czasem wczesnego przyjazdu kierowcy do klienta,
- Niewłaściwe dobranie parametru konserwatyzmu I^{SP} (zbyt małe), nie powoduje ponoszenia potencjalnych strat w odniesieniu do podejścia deterministycznego⁴¹,
- Odpowiedni dobór parametru konserwatyzmu rozwiązania powinno odbywać się po zdobyciu tzw. wiedzy eksperckiej,
- W większości analizowanych parametrów potencjalne zyski/straty są uzależnione od liczebności klientów,
- Wprowadzenie zmienności parametrów modelu VRP zdefiniowanej przez niepewność danych nie wpływa na czas poszukiwania rozwiązania, dzięki zaproponowanemu podejściu integracji odpornego problemu najkrótszej ścieżki z zagadnieniem VRP,

⁴¹ Cecha ta zostanie jeszcze omówiona w dalszej części tego rozdziału.

- Podejście odporne na zmiany w problematyce wyznaczania tras pozytywnie wpływa na czas opóźnienia u klientów oraz w większości przypadków na czas przejazdu pojazdów przez sieć drogową. Zyski te nie odbywają się kosztem zwiększenia liczby tras,
- Koszt uodpornienia rozwiązania na wahania parametrów odbywa się przez nieznaczne zwiększenia długości tras (średnio około 2%) oraz czasu wcześniejszego przyjazdu (średnio o 2,5 minuty więcej na jednego klienta).


6.2.2 WPŁYW TYPU MODELU NA JAKOŚĆ ROZWIĄZANIA

W pracy zaproponowano dwie wersje modeli VRP, stąd naturalnym wydaje się ocena różnic pomiędzy nimi, gdy te wykorzystane są w proponowanym podejściu modelowania zagadnień wyznaczania tras w warunkach niepewności. Analiza została oparta na takiej samej zasadzie jak poprzednio - badano różnicę pomiędzy parametrami oceniającymi⁴². Wyniki zaprezentowano na: rysunkach 6.7 - 6.12.



Rysunek 6.7 Średnia różnica pomiędzy czasem przejazdu w podejściu deterministycznym a czasem przejazdu w podejściu odpornym w zależności od modelu VRP.


Źródło: opracowanie własne.



Rysunek 6.8 Średnia różnica pomiędzy dystansem w podejściu deterministycznym a dystansem w podejściu odpornym w zależności od modelu VRP.


Źródło: opracowanie własne.

⁴² Pominięto kwestię analizy parametrów: liczba tras, czas optymalizacji oraz łączny czas optymalizacji, z uwagi, że wnioski są identyczne jak w przypadku analizy zaprezentowanej w podrozdziale 5.3.2.




Rysunek 6.9 Średnia różnica pomiędzy czasem wczesnego przyjazdu w podejściu deterministycznym a czasem wczesnego przyjazdu w podejściu odpornym w zależności od modelu VRP.

Źródło: opracowanie własne.




Rysunek 6.10 Średnia różnica pomiędzy czasem opóźnienia w podejściu deterministycznym a czasem opóźnienia w podejściu odpornym w zależności od modelu VRP.

Źródło: opracowanie własne.



Rysunek 6.11 Średnia różnica pomiędzy liczbą wczesnych przyjazdów w podejściu deterministycznym a liczbą wczesnych przyjazdów w podejściu odpornym w zależności od modelu VRP.

Źródło: opracowanie własne.




Rysunek 6.12 Średnia różnica pomiędzy liczbą późnych przyjazdów w podejściu deterministycznym a liczbą późnych przyjazdów w podejściu odpornym w zależności od modelu VRP.

Źródło: opracowanie własne.

W przypadku porównywania dwóch wersji modelu wyznaczania tras pojazdów, które zostały zastosowane jako element podejścia dekompozycji odpornego problemu R-TD-VRP-STW, można wskazać niewielką przewagę modelu (nVRP2) nad modelem (nVRP1). Różnice dla wybranych parametrów oceniających, w ramach danego zbioru klientów są niewielkie. W przypadku czasu przejazdu różnica średnich dla wszystkich zbiorów wyniosła zaledwie 0,8 minuty. Jednak pewne różnice można zauważyć w dystansie. Dla pierwszego modelu dla większości zbiorów klientów potencjalne zyski są niewielkie, a większość z nich jest ujemna. Oznacza to, że w porównaniu do podejścia deterministycznego model (nVRP1) odnajduje rozwiązanie, w których łączny dystans jest większy. Wyjaśnieniem tego mogą być wnioski przedstawione w podrozdziale 5.3.2, z których wynikało, że model ten w rozwiązaniu może dawać nieoptymalną liczbę tras. Tak, więc większa liczba tras determinuje większy, łączny pokonany dystans przez pojazdy - średnio o 23%. Dla pozostałych parametrów VRP różnice pomiędzy modelami są nieznaczne. Dodatkowo występuje tendencja wzrostu potencjalnych zysków i/lub strat dla czasu wcześniejszego/późniejszego przyjazdu oraz liczby wczesnych/późnych przyjazdów do klientów, która jest zależna od liczebności zbioru klientów.


6.2.3 WPŁYW STRUKTURY OKIEN CZASOWYCH NA JAKOŚĆ ROZWIĄZANIA

Badanie użyteczności zaproponowanych modeli dla zagadnienia planowania przewozu wykazało, że struktura okien czasowych w zdecydowany sposób wpływa na czas optymalizacji danego modelu. W poniższej analizie sprawdzono, jak ta kwestia wpływa na potencjalne zyski i straty przy stosowaniu zaproponowanej metody. Wykorzystano dwa typy struktury okien czasowych, które zdefiniowano w podrozdziale 5.3. Zyski i/lub straty stosowania podejścia odpornego zaprezentowano na rysunkach 6.13 - 6.18.




Rysunek 6.13 Średnia różnica pomiędzy czasem przejazdu w podejściu deterministycznym a czasem przejazdu w podejściu odpornym w zależności od struktury okien czasowych klientów.

Źródło: opracowanie własne.




Rysunek 6.14 Średnia różnica pomiędzy dystansem w podejściu deterministycznym a dystansem w podejściu odpornym w zależności od struktury okien czasowych klientów.

Źródło: opracowanie własne.




Rysunek 6.15 Średnia różnica pomiędzy czasem wczesnego przyjazdu w podejściu deterministycznym a czasem wczesnego przyjazdu w podejściu odpornym w zależności od struktury okien czasowych klientów.

Źródło: opracowanie własne.




Rysunek 6.16 Średnia różnica pomiędzy czasem opóźnienia w podejściu deterministycznym a czasem opóźnienia w podejściu odpornym w zależności od struktury okien czasowych klientów.

Źródło: opracowanie własne.



Rysunek 6.17 Średnia różnica pomiędzy liczbą wczesnych przyjazdów w podejściu deterministycznym a liczbą wczesnych przyjazdów w podejściu odpornym w zależności od struktury okien czasowych klientów.

Źródło: opracowanie własne.



Rysunek 6.18 Średnia różnica pomiędzy liczbą późnych przyjazdów w podejściu deterministycznym a liczbą późnych przyjazdów w podejściu odpornym w zależności od struktury okien czasowych klientów.

Źródło: opracowanie własne.

Potencjalne zyski w czasie przejazdu są większe w zagadnieniach VRP, w których występuje większa pula klientów ze zdefiniowanymi oknami czasowymi. Dla prawie 70% przypadków odnotowano większy profit czasu przejazdu - średnio 13,6 minuty. W kwestii pokonanego dystansu również wariant "okna - wszyscy" jest korzystniejszy. Dla liczebności klientów $n = \{20; 25; 30\}$ wariant "okna-mieszane" wykazuje pozytywne aspekty stosowania w odniesieniu do podejścia deterministycznego. W pozostałych przypadkach tego typu struktura

okien czasowych obsługi wpływa niekorzystnie na zysk łącznego dystansu - średnie zwiększenie wartości o 2,4 km. W sytuacji, gdy każdy klient ze zbioru ma przypisane okna czasowe, ewentualne zyski lub straty rozkładają się po równo - średnia jest bliska zeru.

Średnia różnica czasu wcześniejszego przyjazdu oraz liczby wcześniejszych przyjazdów jest ujemna i większa dla struktury okien czasowych "okna - mieszane" (rysunek 6.15 oraz rysunek 6.17). Interpretacja takiego wyniku może być następująca - mniejsza liczba klientów z przypisanymi oknami automatycznie wpływa na zmniejszenie potencjalnych łącznych strat. Jeśli jednak przeliczy się średnią łączną stratę czasu wcześniejszego przyjazdu na jednego klienta, okaże się, że w wariancie z mieszanymi oknami wartość ta wynosi 12,8 minuty, a dla drugiego 10,7 minuty. Globalnie straty czasu wcześniejszego przyjazdu zmalały, a dla indywidualnych klientów wartość tego czasu wzrosła. Dla parametrów: czas opóźnienia oraz liczba opóźnień wnioski są analogiczne - im więcej klientów z przypisanymi oknami czasowymi tym ewentualne zyski są większe. Dla tych parametrów indywidualny czas opóźnienia na jednego klienta jest na tym samym poziomie (występuje różnica ułamka minuty).

6.2.4 ANALIZA ZMIENNOŚCI ZNORMALIZOWANEJ WARTOŚCI FUNKCJI KRYTERIALNEJ DLA PODEJŚCIA DETERMINISTYCZNEGO I ODPORNOŚCIOWEGO

Zanim zostaną sformułowane wnioski końcowe, zostanie przedstawiony jeszcze jeden przykład symulacyjny, który będzie bardzo trafną ilustracją cech optymalizacji typu odporne-go na wahania parametrów modelu VRP. Badanie zostało wykonane dla przykładu testowego o liczebności 20 klientów, ze strukturą okien czasowych "okna - wszyscy", wykorzystując model matematyczny ($nVRP2$) oraz zakładając maksymalną liczbę tras w rozwiązaniu $K = 3$. Celem badania będzie identyfikacja zmienności znormalizowanej wartości funkcji kryterialnej zdefiniowanej w modelu ($nVRP2$) w zależności od: stopnia zakładanej niepewności danych w modelu oraz od stopnia realizacji niepewności danych. Badanie to zostało wykonane w dwóch wariantach: deterministycznym i odpornościowym.

Dotychczasowe analizy w podejściu deterministycznym zakładały, że wyznaczanie tras pojazdów jest wykonywane w oparciu o wartość oczekiwaną czasu przejazdu określoną średnią. Ze względu na swoją prostotę, sposób ten jest najczęściej spotykanym podejściem wykorzystywanym przez planistów, czy też używany w programach wspomagających podejmowanie decyzji dedykowanych dla planistów. Posiadając informację o przewidywanej odchyłce od wartości średniej, powstaje pytanie: jak uwzględnianie wahań wartości czasu przejazdu od wartości oczekiwanej w podejściu deterministycznym wpływa na rozwiązanie finalne? W podejściu odpornym losowa perturbacja została wykorzystana do zdefiniowania zbioru niepewności danych i jak do tej pory wykazano, że tworzy to potencjalne zyski. Aby odpowiedzieć na postawione pytanie wykonano analizę wpływu uwzględniania wahań wartości w zakresie od 0% do 100%. Założono, że czas przejazdu w sieci drogowej wykorzystywany do planowania tras jest stopniowo zmieniany przez dodawanie części potencjalnego odchylenia do wartości średniej. Krok zwiększania potencjalnych wahań wartości został przyjęty jako 2%. Deterministyczny model wyznaczania tras został oparty o proponowaną koncepcję integracji z problematyką wyznaczania najkrótszych ścieżek. Wykorzystano deterministyczny model (SPP^T), w którym czas przejazdu był zmieniany w macierzy \mathbf{TT}_{org}^{SP} w następujący sposób:


$$\mathbf{T}\mathbf{T}_{e_{org}}^{SP} = \left[\bar{t}_{ij}^{SP}(\tau_{e_{org}}) + dev \cdot \hat{t}_{ij}^{SP}(\tau_{e_{org}}) : \forall (i, j) \in \mathbf{AS} \wedge \exists \tau_{e_{org}} \in \mathbf{T} : e_{org} \in]U_{\tau-1}, U_{\tau}] \right] \quad (6.4)$$

gdzie dev oznacza stopień uwzględniania potencjalnych wahań wartości parametrów modelu, wyrażony procentowo z zakresu [0%; 100%] i z krokiem co 2%. Na bazie obliczonych najkrótszych ścieżek wyznaczono trasy pojazdów zgodnie z założeniami modelu ($nVRP2$).

Każdy z otrzymanych przypadków został podany ocenie jakości uzyskanego rozwiązania zgodnie ze schematem i założeniami przedstawionymi na początku tego podrozdziału. Dla każdego rozwiązania generowano zestaw 50 losowych scenariuszy z założeniem stopniowego zwiększania udziału odchylenia standardowego w czasie przejazdu. Formalnie można to zapisać (oparte o sformułowanie (6.1)):

$$\left(\bar{\mathbf{T}}\mathbf{T}_{e_{org}}^{SP} \right)_{\%} = \left\{ \left[\bar{t}_{ij}^{SP}(\tau_{e_{org}}) + \varepsilon_{\%} \cdot \delta_{ij}^{SP}(\tau_{e_{org}}) \right], \delta_{ij}^{SP}(\tau_{e_{org}}) \sim N \left(\bar{t}_{ij}^{SP}(\tau_{e_{org}}), \hat{t}_{ij}^{SP}(\tau_{e_{org}}) \right), \forall (i, j) \in \mathbf{AS} \wedge r = 1, \dots, 6, \exists \tau_{e_{org}} \in \mathbf{T} : e_{org} \in (U_{\tau-1}, U_{\tau}] \right\} \quad (6.5)$$

Parametr $\varepsilon_{\%}$ jest losową wartością z rozkładu równomiernego opisującą stopień realizacji odchylenia standardowego w scenariuszu, który był zmieniany w zakresie [0%; 150%] z krokiem co 2%. Ma to na celu uzyskanie symulacji przejścia od sytuacji gdzie prognoza czasu przejazdu jest niewłaściwa (za mała), poprzez sytuację, gdzie prognoza jest bardzo dobrej jakości, aż do sytuacji gdzie prognoza jest przeszacowana. Dla każdego zestawu 50 scenariuszy w obrębie jednego przykładu testowego obliczono średnią dla znormalizowanych wartości funkcji celu. Otrzymane wyniki zmienności znormalizowanej wartości funkcji kryterialnej modelu ($nVRP2$) zaprezentowano na rysunku 6.19.




Rysunek 6.19 Wpływ zmiany stopnia odchylenia wartości czasu przejazdu i stopnia realizacji danych na znormalizowaną wartość funkcji celu w podejściu deterministycznym.

Źródło: opracowanie własne.

Dla porównania otrzymanych wyników podobną analizę przeprowadzono w proponowanej wersji odpornej. Stopień uwzględniania możliwej perturbacji został określony przez war-

tość poziomu konserwatywności Γ . Zbadano zmienność wartości funkcji kryterialnej w zależności od wartości tego parametru dla zakresu $\Gamma \in [0; 100]$ z krokiem co 2. Analogicznie każde z otrzymanych rozwiązań poddano ocenie na podstawie generowania losowych scenariuszy. Wyniki przedstawia rysunek 6.20.



Rysunek 6.20 Wpływ zmiany poziomu konserwatywności i stopnia realizacji danych na znormalizowaną wartość funkcji celu w podejściu odpornym.

Źródło: opracowanie własne.

Przedstawione powyżej wykresy są bardzo dobrym podsumowaniem prowadzonej analizy. Stosowanie wariantu deterministycznego do planowania przewozu ładunków na obszarach miejskich wykazuje się niesatysfakcjonującym rezultatem. Nawet, gdy uwzględnia się potencjalne odchylenia od wartości średniej czasu przejazdu w sieci drogowej rezultaty mogą być kosztowne. Nie można wskazać jakiegokolwiek tendencji zmiany wartości funkcji celu modelu VRP przy zmienianiu wartości odchylenia standardowego. Świadczą o tym kolejne, nagłe przeskoki wzdłuż osi "Udział odchylenia czasu przejazdu w modelu [%]". Takie przebiegi funkcji oznaczają, że inny zbiór danych generuje zupełnie inny zbiór rozwiązań, co powoduje, że wyniki są trudne do przewidzenia. Dodatkowo przyjęcie udziału odchylenia w danych wcale nie gwarantuje, że przy rzeczywistej realizacji czasu przejazdu, koszty będą mniejsze. Analiza przebiegu funkcji wzdłuż osi "Udział odchylenia czasu przejazdu w symulacji [%]" wskazuje, że wartość funkcji też może rosnąć wraz ze wzrostem różnicy pomiędzy prognozowanymi a rzeczywistymi wartościami czasu przejazdu. Rozkładając znormalizowaną wartość funkcji celu na poszczególne elementy składowe można wskazać, że jest to spowodowane wzrostem łącznego czasu przejazdu oraz czasu opóźnienia dla danego rozwiązania.

W przypadku podejścia odpornego na wahania parametrów modelu można zaobserwować pozytywne wyniki stosowania. Do pewnego poziomu konserwatywności zmienność funkcji celu modelu ($nVRP2$) jest również skokowa, jednak zmiany te nie są tak duże jak w przypadku podejścia deterministycznego. Co więcej, możliwe jest wskazanie pewnych charakterystycznych cech. Źle oszacowana prognoza, w stosunku do rzeczywistej realizacji skutkuje ponoszeniem kosztów. Na wykresie są to wysokie "grzbiety funkcji". Jednak największe wartości są osiągane tylko i wyłącznie przy kompletnie niewłaściwie dobranej prognozie np. zakłada się dość wysoką zmienność czasu przejazdu, a w rzeczywistości zmiany były niewielkie (na wy-

kresie $I^{SP} = 34$ i udział odchylenia w symulacji 0-30% wartości oczekiwanej). Nawet w takich przypadkach całkowita wartość funkcji celu jest mniejsza, niż wartości większości pików na rysunku 6.19. Szczytowe wartości na rysunku 6.20 oznaczają czas wcześniejszego przyjazdu (wierzchołki funkcji bliższe na wykresie) oraz czas opóźnienia (wierzchołki funkcji dalsze na wykresie). Dodatkowo, odchyłka rzeczywistych wartości od estymowanych o $(+/-50\%)$, gwarantuje, że wartość funkcji celu będzie bliska minimum.

Podejście odporne na wahania parametrów modelu posiada jeszcze jedną bardzo ważną cechę: po przekroczeniu pewnej wartości poziomu konserwatyźmu, wartość funkcji celu jest mocno ujednoczona, niezależnie od poziomu realizacji danych rzeczywistych. Cecha ta gwarantuje, że nawet przy niewłaściwym doborze parametru Γ , otrzymane rozwiązanie będzie charakteryzować się dobrą jakością. Stabilność rozwiązania i kosztów są zachowane nawet po przekroczeniu wartości zdefiniowanych zakresem zbioru niepewności danych. Jest to szczególnie ważne przy wysokiej zmienności parametrów ruchu drogowego.

6.3 PORÓWNANIE WARIANTU ODPORNOŚCIOWEGO Z WARIANTEM STOCHASTYCZNYM

Do tej pory w analizach zaprezentowano zalety i wady stosowania podejścia uwzględniającego niepewność parametrów modelu VRP w odniesieniu do klasycznego i popularnego podejścia deterministycznego. Jak już wspomniano to wcześniej, innym równie popularnym⁴³ podejściem jest wykorzystanie optymalizacji stochastycznej. Podobnie jak w optymalizacji odpornej zakłada się możliwość zdefiniowania zmienności parametrów modelu. Różnica polega na założeniu, że występujące zmiany są opisane znanym rozkładem prawdopodobieństwa. O ile założenie to, przy stabilności zmienności parametrów i przy występowaniu typowych zjawisk, może być właściwe, to przy występowaniu incydentów nietypowych, już nie do końca. Sprawdzenie tej własności jest jednym z celów poniższego porównania.

Porównania dokonano dla trzech wersji poziomów prawdopodobieństwa wariantu stochastycznego z wariantem odpornym na wahania przyjmując poziom konserwatyźmu rozwiązania $\Gamma = 20$. Z poprzedniej analizy wynikało, że im jest mniejsza liczba klientów z oknami czasowymi tym potencjalne zyski są mniejsze. Z tego powodu porównania dokonano tylko dla przykładów testowych ze strukturą okien "wszyscy". Ma to na celu sprawdzenie jakie są maksymalne potencjalne różnice pomiędzy oboma podejściami. Odniesieniem w analizie były wyniki podejścia stochastycznego, tak więc ujemne wartości porównania oznaczają potencjalne straty, a dodatnie oznaczają potencjalne zyski stosowania proponowanego podejścia.

Dokonano również modyfikacji losowej zmiany stopnia realizacji niepewności. Założono 5 scenariuszy ε_r , które przyjmowały losowe wartości z przedziału:

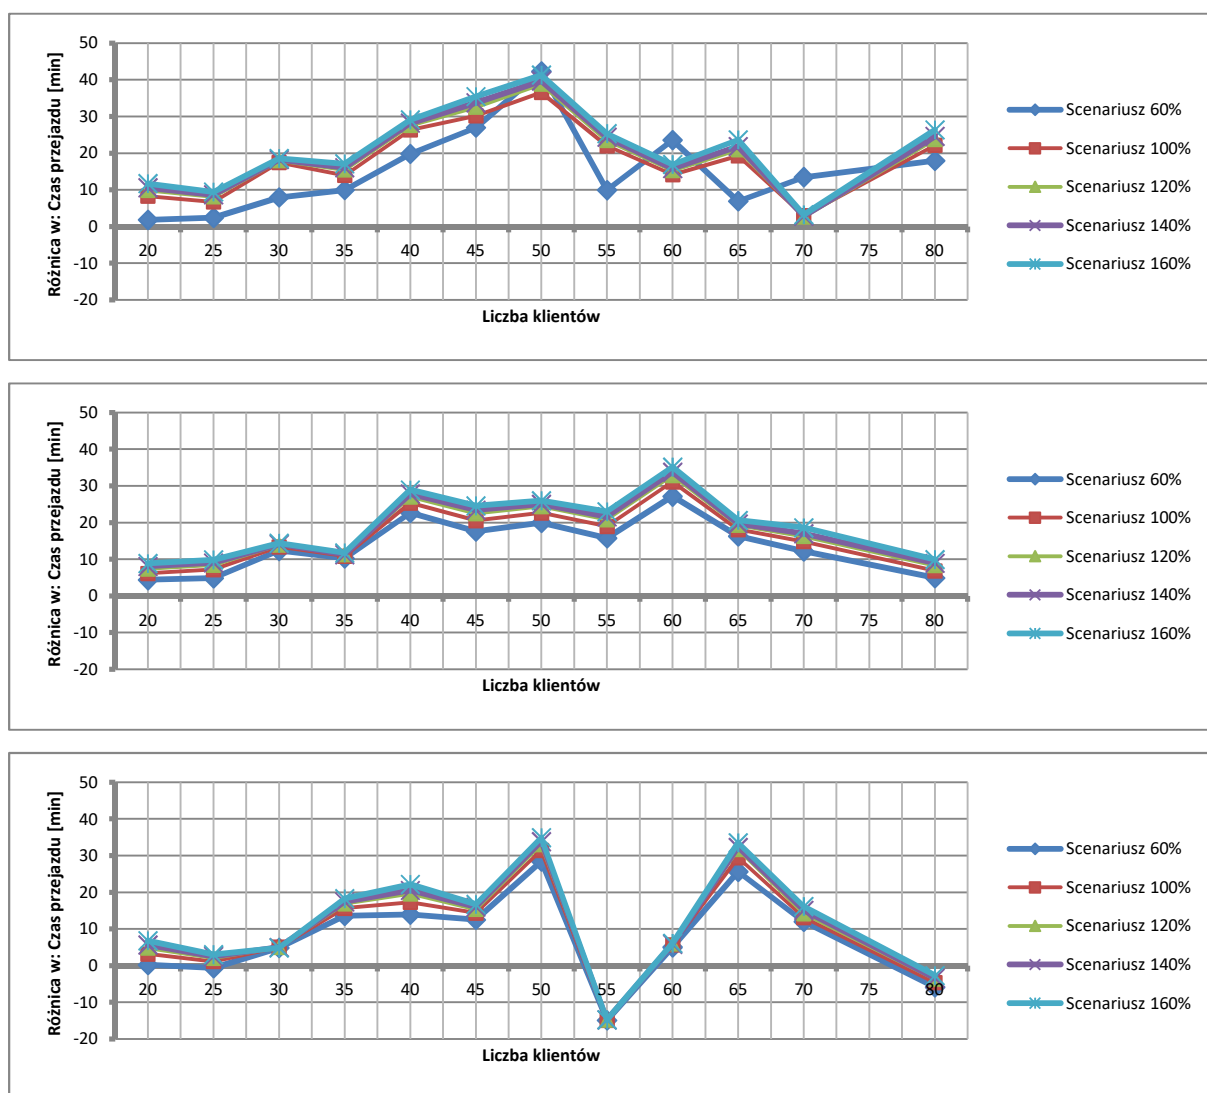
- $\varepsilon_1 \in [0,3; 0,6]$ - dalej "Scenariusz 60%",
- $\varepsilon_2 \in [0,6; 1,0]$ - dalej "Scenariusz 100%",
- $\varepsilon_3 \in [0,8; 1,2]$ - dalej "Scenariusz 120%",
- $\varepsilon_4 \in [0,8; 1,4]$ - dalej "Scenariusz 140%",
- $\varepsilon_5 \in [1,0; 1,6]$ - dalej "Scenariusz 160%".

⁴³ Szczególnie w badaniach teoretycznych i badaniach naukowych.

Sposób generowania losowych scenariuszy pozostał taki sam jak w poprzedniej analizie. Analizę porównawczą ograniczono tylko to określenia różnicy pomiędzy podejściami w rozróżnieniu od liczebności zbiorów klientów oraz przyjętego poziomu prawdopodobieństwa. Pominięto kwestie związane z typem modelu oraz rodzaju okien czasowych, ponieważ cechy otrzymanych rozwiązań są analogiczne jak w poprzednich badaniach (podrozdział 6.2).

6.3.1 WPŁYW LICZEBNOŚCI KLIENTÓW I POZIOMU KONSERWATYZMU NA JAKOŚĆ ROZWIĄZANIA

Podobnie jak przy porównywaniu wariantu deterministycznego, rozważania rozpoczęto od sprawdzenia jaki poziom prawdopodobieństwa modelu stochastycznego wpływa na potencjalne różnice z podejściem odpornym na wahania parametrów oraz czy występuje zależność od liczności zbioru klientów. Pierwszym parametrem oceniającym jest łączny czas przejazdu - średnie wartości różnic przedstawiają wykresy na rysunku 6.21.



Rysunek 6.21 Średnia różnica pomiędzy czasem przejazdu wariantu stochastycznego a wariantu odpornego przy $\Gamma = 20$ w zależności od liczby klientów oraz stopnia realizacji niepewności danych.

Wykres górny dla $1 - \alpha = 0,65$; wykres środkowy dla $1 - \alpha = 0,80$; wykres dolny dla $1 - \alpha = 0,95$.

Źródło: opracowanie własne.

Niezależnie od rodzaju losowej realizacji niepewności danych dla ponad 90% przypadków, występuje pozytywna wartość różnicy w średnim czasie trwania poruszania się pojazdów w sieci drogowej. Dodatkowo bez względu na poziom prawdopodobieństwa, istnieje silna korelacja (przeważnie współczynnik $R^2 \geq 90\%$) pomiędzy wielkością zysków, a realizacją niepewności danych. Im losowa realizacja czasu przejazdu różni się od zakładanych zmienności, tym zyski czasu przejazdu są większe. Druga dość ważna kwestia to zależność od przyjętego poziomu prawdopodobieństwa. Przyjmowanie większej wartości prawdopodobieństwa, że ograniczenia modelu zostaną spełnione powoduje zmniejszenie różnicy pomiędzy podejściami. Jednak średnio wartość ta spada do różnicy około 10 minut, która stanowi średnio 4,5% czasu przejazdu wariantu stochastycznego. Wysokie prawdopodobieństwo spełnienia ograniczenia np. $(1 - \alpha) = 0,95$ oznacza, że dla 95% losowych wartości czasu przejazdu ograniczenia modelu zostaną zachowane. Zatem odnosząc się do charakterystyki rozkładu normalnego zakres zmienności zmiennej losowej jest bardzo szeroki, co w konsekwencji prowadzi do zakładania wersji pesymistycznej (zmierza do wyboru najlepszych z najgorszych). Z kolei przy przyjęciu mniejszej wartości prawdopodobieństwa $(1 - \alpha)$, potencjalne zyski rosną do średniego poziomu 19 minut, co opowiada średniej redukcji czasu o 9,1%. W najlepszym przypadku zmniejszenie łącznego czasu jazdy wyniosło 42 minuty (ponad 14% redukcji). Dodatkowo nie występuje zależność potencjalnych zysków/strat od liczebności zbioru klientów.

Optymalizacja zakładająca minimalizację wielu kryteriów często charakteryzuje się występowaniem rozwiązań kompromisowych, w których poprawa jednego kryterium jest kosztem drugiego. I tak też jest w tym wypadku, potencjalne zyski czasu przejazdu są wynikiem pogorszenia wartości kolejnych parametrów (ale nie wszystkich). Pierwszym z nich jest dystans. Wyniki porównania średniej łącznej długości tras zaprezentowano w tabeli 6-4.

Tabela 6-4 Różnica pomiędzy dystansem wariantu stochastycznego a wariantu odpornego w zależności od liczby klientów oraz wartości parametru konserwatywności oraz procentowy wzrost/spadek.

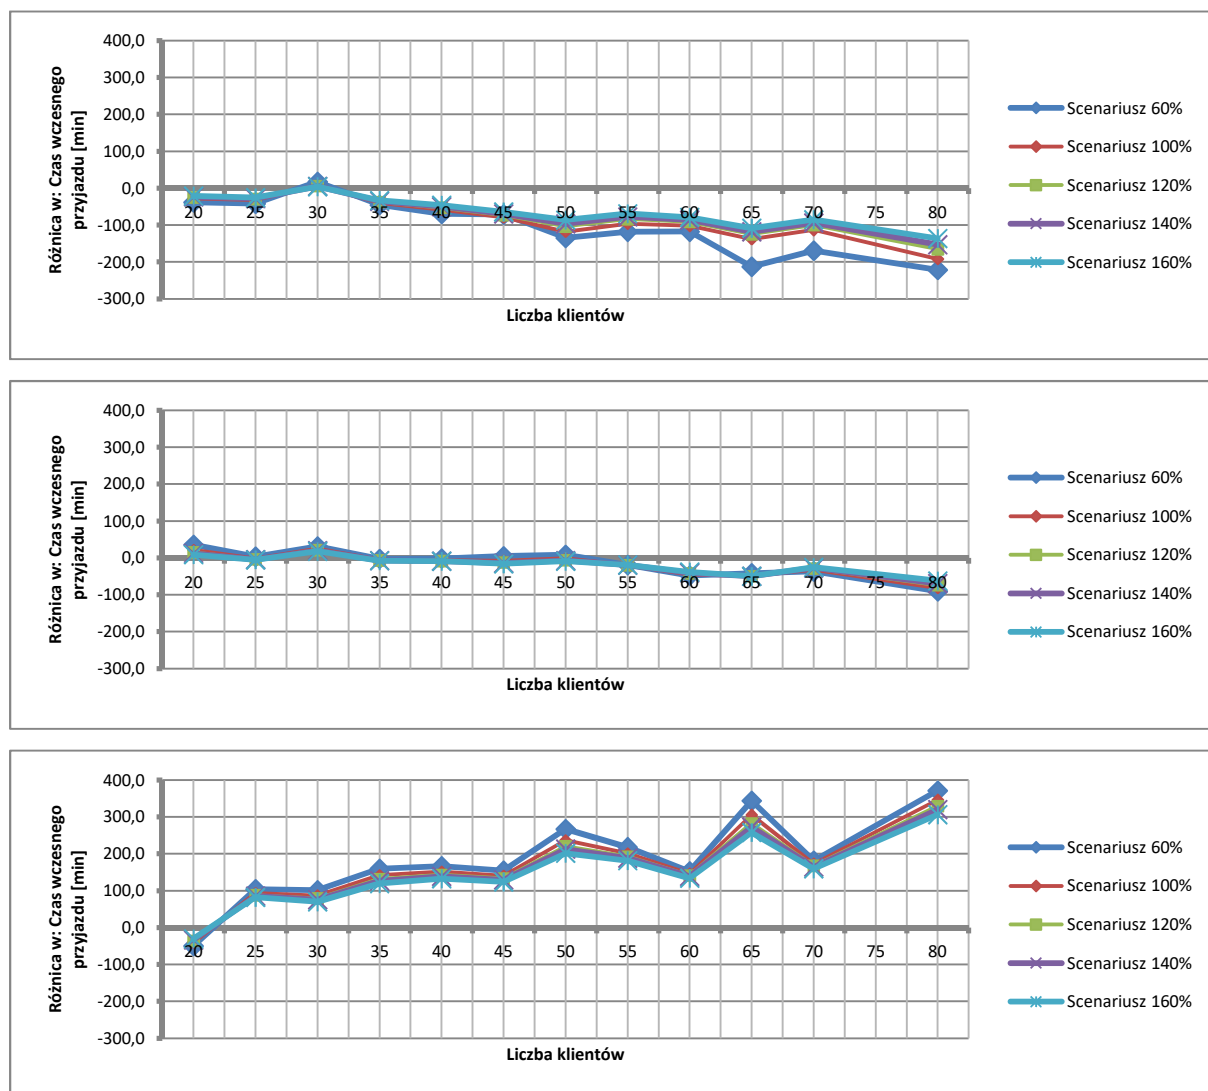
Różnica w: Dystans [km]													
(1-alfa) =	Liczba klientów												
	20	25	30	35	40	45	50	55	60	65	70	75	80
0,65	-1 055,1	-2 420,0	-1 394,6	-1 561,7	-510,6	3 375,0	345,6	307,0	-629,4	-7 271,8	-9 754,9	-	-3 003,4
0,80	-1 233,7	-2 322,9	-3 475,0	-848,3	1 229,6	127,8	-1 577,9	-1 724,0	3 319,1	-5 486,1	-5 373,6	-	-10 800,1
0,95	-3 756,3	-3 806,0	-1 607,6	-573,4	2 144,6	1 133,1	4 313,4	-11 527,5	-2 905,3	-4 911,5	-2 718,8	-	-8 498,4
Średnia	-2 015,0	-2 849,6	-2 159,1	-994,5	954,5	1 545,3	1 027,0	-4 314,8	-71,9	-5 889,8	-5 949,1	-	-7 434,0
Procentowy wzrost/spadek łącznego dystansu													
0,65	-3,2%	-5,7%	-4,6%	-3,4%	-2,3%	5,0%	0,5%	0,2%	-1,8%	-9,6%	-11,1%	-	-4,7%
0,80	-4,1%	-5,9%	-9,4%	-2,4%	1,6%	0,0%	-3,4%	-3,0%	4,1%	-7,6%	-6,1%	-	-11,9%
0,95	-10,3%	-10,2%	-5,1%	-1,7%	2,9%	2,1%	5,8%	-20,2%	-4,2%	-6,1%	-3,0%	-	-9,9%

Źródło: opracowanie własne.

W większości przypadków (75%) pokonany dystans zwiększył się przeciętnie o 3,7 km (średni wzrost o 6,3%). Dla pozostałych przypadków odnotowano skrócenie dystansu średnio o 1,8 km (przeciętna redukcja o 2,5%). Podobnie jak poprzednio nie można jednoznacznie wskazać istnienia zależności zmiany zysków/strat od liczebności zbioru klientów. Dla kolejnych poziomów prawdopodobieństwa można zauważyć tendencję wzrostu różnicy dystansu

pomiędzy podejściami, jednak tylko w ujęciu średnim dla danego prawdopodobieństwa. Analizując poszczególne przykłady testowe, zależność ta jest różna i niezauważalna.

Średnia różnica łącznego czasu wcześniejszego przyjazdu została zaprezentowana na wykresach poniżej (Rysunek 6.22), a średnia różnica w liczbie wystąpień tych czasów zaprezentowano na rysunku 6.23. Czas wczesnego przyjazdu jest mniejszy dla wariantu stochastycznego w przypadkach gdzie prawdopodobieństwo $(1 - \alpha)$ jest mniejsze. Wraz ze wzrostem tego parametru zauważalny jest istotny wzrost tej różnicy czasu do poziomu przekraczającego znacznie wynik podejścia stochastycznego. Dla $(1 - \alpha) = 0,65$ średnia strata dla wszystkich przypadków to około 77 min, w przeliczeniu na jednego klienta to 16,5 minuty. Równolegle wzrasta również liczba klientów, do których kierowca przyjechał za wcześnie - średnio wzrost o 4,2 klienta na rozwiązanie.



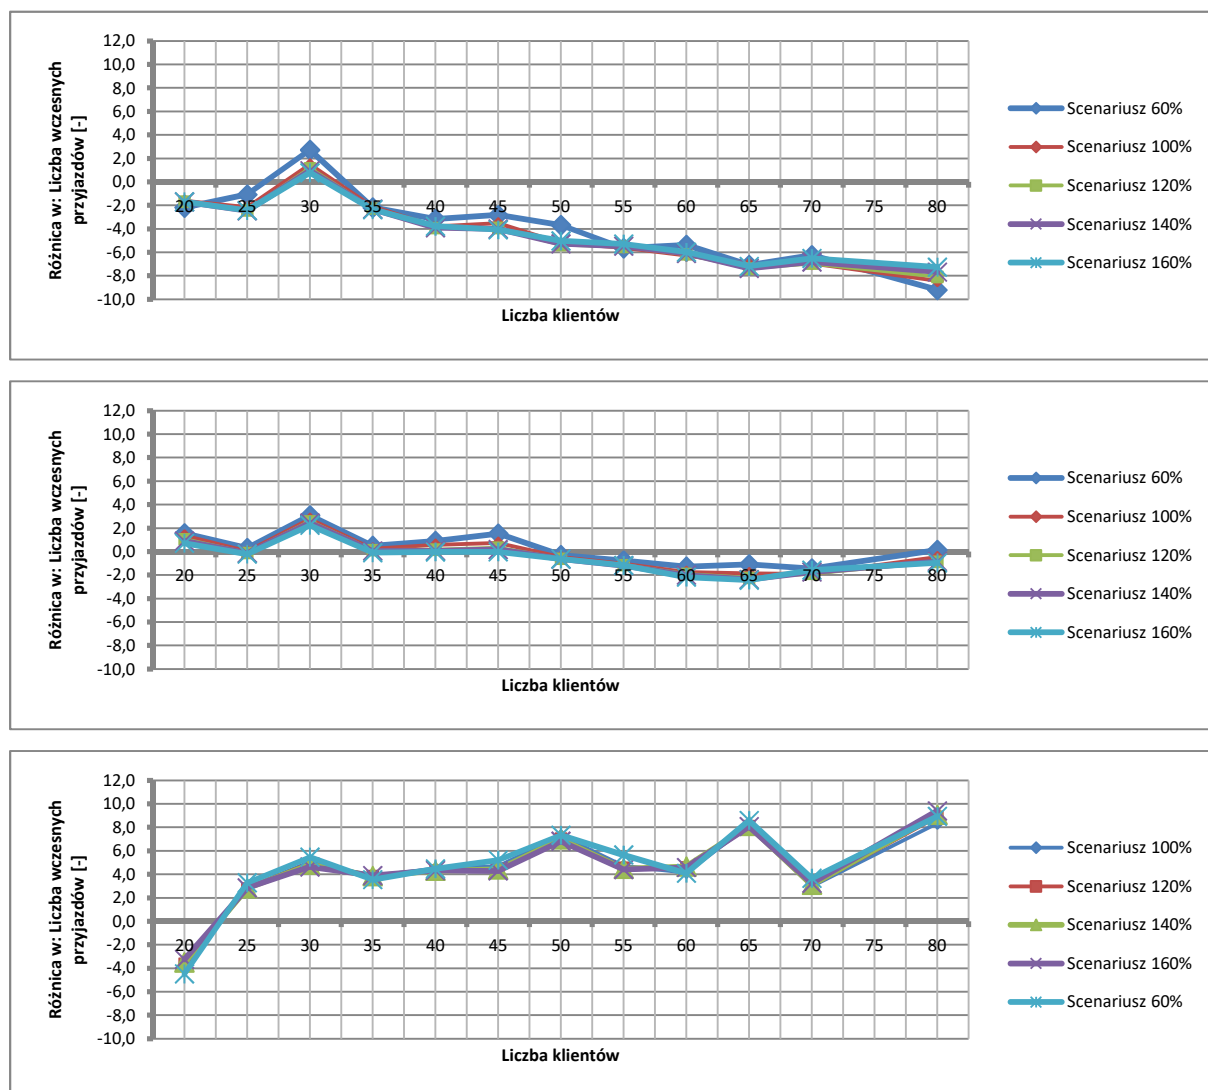
Rysunek 6.22 Średnia różnica pomiędzy czasem wczesnych przyjazdów wariantu stochastycznego a wariantu odpornego przy $\Gamma = 20$ w zależności od liczby klientów oraz stopnia realizacji niepewności danych.

Wykres górny dla $1 - \alpha = 0,65$; wykres środkowy dla $1 - \alpha = 0,80$; wykres dolny dla $1 - \alpha = 0,95$.

Źródło: opracowanie własne.

Przykłady z prawdopodobieństwem na poziomie 80% wykazują się przeciętnie 16 minutami straty. Jednakże różnica w liczbie wczesnych przyjazdów oscyluje wokół zera. Dla naj-

większej wartości prawdopodobieństwa model stochastyczny wykazuje się stratami w stosunku do podejścia odpornego i średni zysk jest na poziomie 32,4 minuty na jednego klienta. Nawiązując do wniosków z analizy czasu przejazdu, jest to dość logiczny wniosek, ponieważ szeroki zakres zmienności czasu zdefiniowany wysokim poziomem prawdopodobieństwa, determinuje poszukiwania rozwiązania, które będzie dopuszczalne dla wielu scenariuszy. Niesie to za sobą koszt w postaci, zachowawczego wyznaczenia tras, w których czas oczekiwania jest duży. Dodatkowo można zaobserwować jeszcze trzy cechy: w przypadkach testowych, gdzie występuje strata czasu wczesnego przyjazdu, wielkość ta rośnie wraz z błędem prognozy⁴⁴. W przykładach gdzie występują zyski czasu wczesnego przyjazdu wartość ich jest tym większa im większy błąd prognozy. Istnieje również zależność wzrostu zysku/straty od liczebności zbioru klientów.



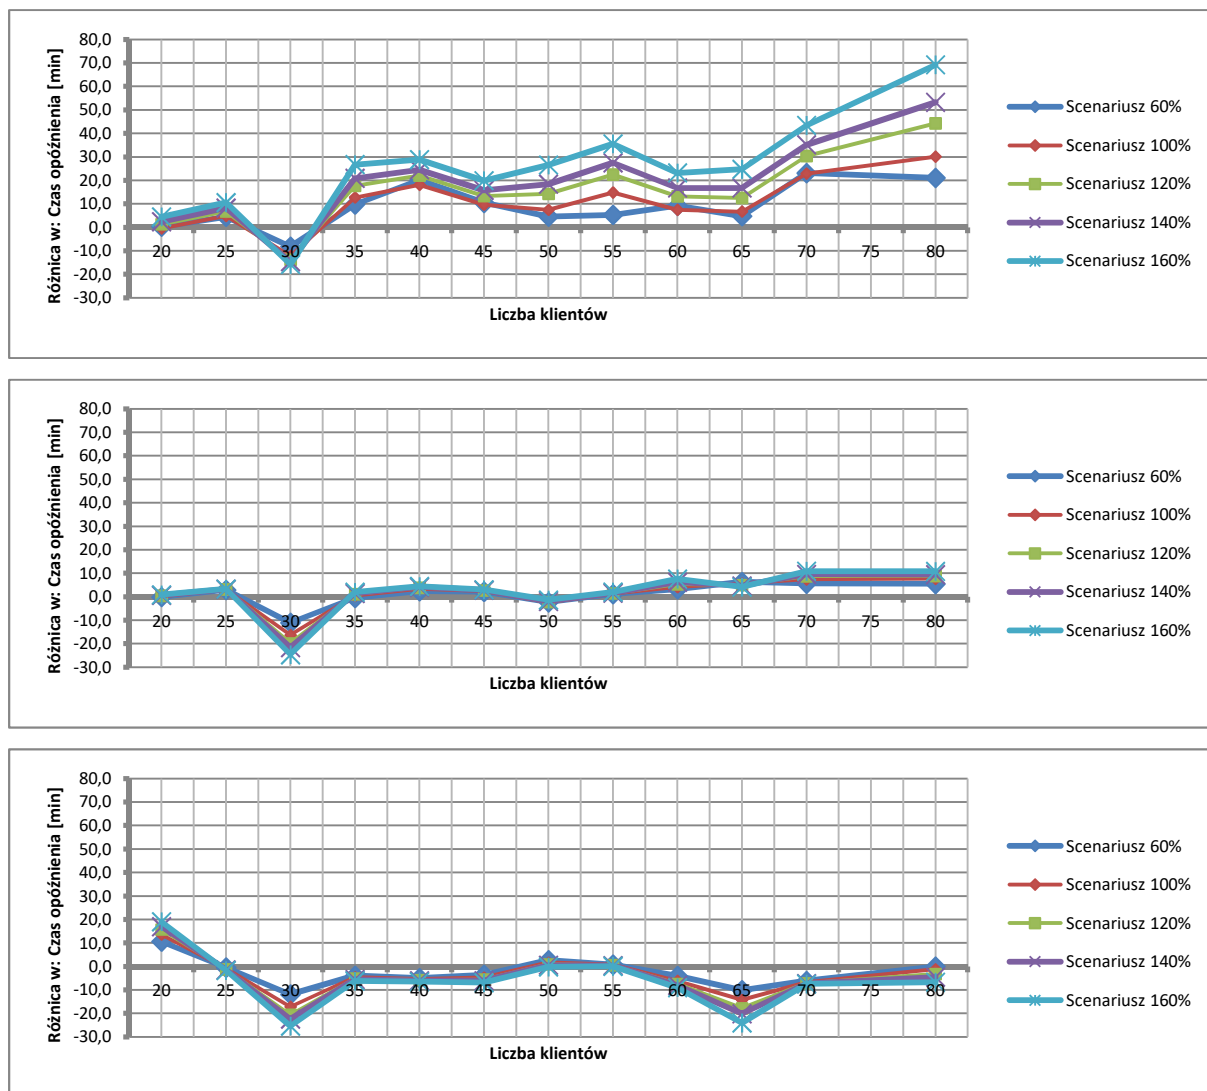
Rysunek 6.23 Średnia różnica pomiędzy liczbą wczesnych przyjazdów wariantu stochastycznego a wariantu odpornego przy $\Gamma = 20$ w zależności od liczby klientów oraz stopnia realizacji niepewności danych.

Wykres górny dla $1 - \alpha = 0,65$; wykres środkowy dla $1 - \alpha = 0,80$; wykres dolny dla $1 - \alpha = 0,95$.

Źródło: opracowanie własne.

⁴⁴ Błąd prognozy jest rozumiany jako różnica pomiędzy planowanymi czasami przejazdu, a rzeczywistą realizacją tego czasu przejazdu (tutaj wygenerowaną losowo).

Kolejne dwa parametry opisujące jakość obsługi związaną z oknami czasowymi u klientów to czas opóźnienia oraz liczba opóźnień w rozwiązaniu. Podobnie jak w poprzedniej analizie porównawczej, można zaobserwować generalny trend pomiędzy czasem wcześniejszego przyjazdu a czasem opóźnienia: jeśli opóźnienie rośnie to czas oczekiwania maleje (średnio). Jednak nie jest to wynikiem kompensacji jednego parametru przez drugi - wartości różnic są inne. Stąd im większy zostanie przyjęty poziom prawdopodobieństwa, tym mniejsza jest przeciętna różnica pomiędzy modelem stochastycznym a odpornym na wahania parametrów modelu. Na rysunku 6.24 oraz rysunku 6.25 zaprezentowano analizę związaną z czasem opóźnienia i liczbą opóźnień.



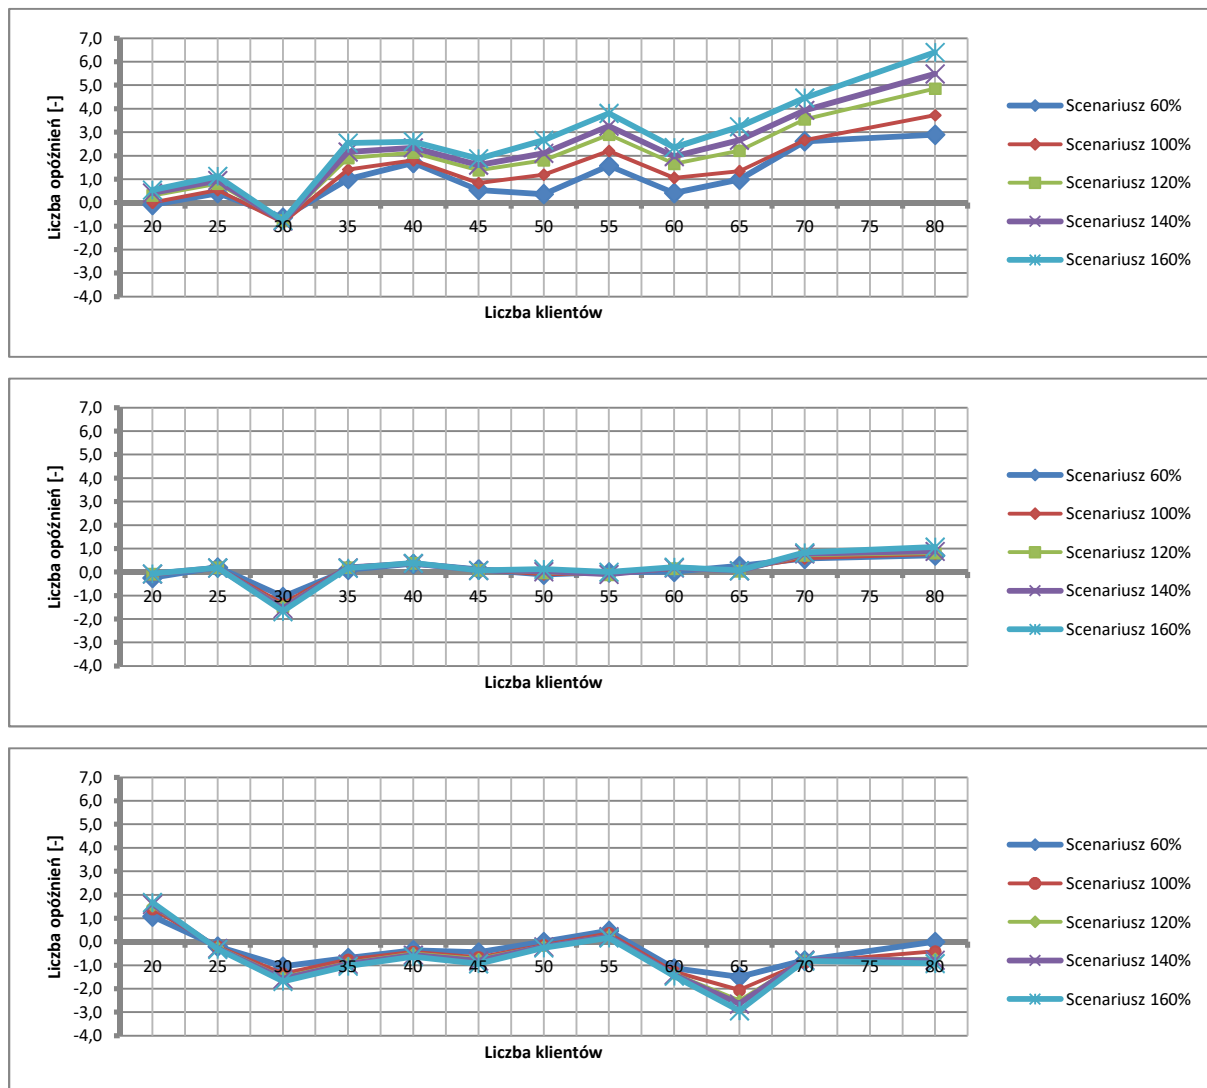
Rysunek 6.24 Średnia różnica pomiędzy czasem opóźnienia wariantu stochastycznego a wariantu odpornego przy $\Gamma = 20$ w zależności od liczby klientów oraz stopnia realizacji niepewności danych.

Wykres górny dla $1 - \alpha = 0,65$; wykres środkowy dla $1 - \alpha = 0,80$; wykres dolny dla $1 - \alpha = 0,95$.

Źródło: opracowanie własne.

Zgodnie z uzyskanymi wynikami można zaobserwować, że w przypadku największego poziomu prawdopodobieństwa oba porównywane podejścia dają zbliżone wyniki. Średnia różnica czasu opóźnienia dla rozwiązania to tylko 4,5 minuty, a liczba klientów, u których kierowca może pojawić się poza sztywnym oknem czasowym wzrosła o 0,6. Dla porównania

dla wartości $(1 - \alpha) = 65\%$ zyski plasują się na poziomie 15 minut na rozwiązanie, a liczba opóźnień spadła o 1,7 klientów. Badanie to wskazuje więc przewagę podejścia odpornego nad podejściem stochastycznym.



Rysunek 6.25 Średnia różnica pomiędzy liczbą opóźnień wariantu stochastycznego a wariantu odpornego przy $T = 20$ w zależności od liczby klientów oraz stopnia realizacji niepewności danych.

Wykres górny dla $1 - \alpha = 0,65$; wykres środkowy dla $1 - \alpha = 0,80$; wykres dolny dla $1 - \alpha = 0,95$.

Źródło: opracowanie własne.

Liczba uzyskanych tras w rozwiązaniu jest ostatnim bardzo ważnym parametrem, który świadczy o jakości rozwiązania. W tabeli 6-5 zaprezentowano minimalną, średnią oraz maksymalną liczbę tras, jaka została utworzona w drodze optymalizacji dla każdego z podejść. Zastosowana optymalizacja stochastyczna wykazuje tendencję do odnajdywania rozwiązania o większej liczbie tras. Zależność ta występuje w większości poszczególnych przypadków niezależnie od prawdopodobieństwa. Oznacza to, że potencjalne zyski np. w mniejszym czasie opóźnienia wynikają ze zwiększonej liczby tras, co automatycznie zwiększa niezawodność takiego rozwiązania. Jest to spowodowane tym, że im większa liczba to tras, tym mniejsza liczba klientów na jedną trasę, czyli mniejszy efekt propagacji opóźnienia. Również z punktu

widzenia firmy wykorzystanie dodatkowego pojazdu do realizacji dodatkowej trasy istotnie wpływa na koszty funkcjonowania.

Tabela 6-5 Minimalna, średnia i maksymalna liczba tras w rozwiązaniu zagadnienia VRP dla podejścia stochastycznego i odpornego.

Wariant	Liczba klientów													
	Liczba tras:	20	25	30	35	40	45	50	55	60	65	70	75	80
Odporny	minimalna	1,0	1,0	1,0	2,0	2,0	2,0	2,0	3,0	3,0	3,0	4,0	-	4,0
	średnia	1,6	2,0	2,0	2,5	2,8	3,0	3,0	3,3	3,0	4,0	4,0	-	4,0
	maksymalna	2,0	3,0	3,0	3,0	3,0	5,0	5,0	4,0	3,0	5,0	4,0	-	4,0
(1-alfa) = 65%	minimalna	1,0	1,0	1,0	1,0	2,0	2,0	2,0	2,0	3,0	3,0	3,0	-	3,0
	średnia	2,4	2,4	2,5	2,7	3,0	3,4	3,3	3,5	3,7	3,7	3,8	-	4,0
	maksymalna	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	-	5,0
(1-alfa) = 80%	minimalna	1,0	1,0	1,0	1,0	1,0	2,0	2,0	2,0	2,0	3,0	3,0	-	3,0
	średnia	2,2	2,5	2,5	2,7	3,1	3,1	3,1	3,4	3,6	3,9	3,9	-	4,1
	maksymalna	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	5,0	-	5,0
(1-alfa) = 95%	minimalna	1,0	1,0	1,0	2,0	2,0	2,0	2,0	3,0	3,0	3,0	4,0	-	4,0
	średnia	1,8	2,0	2,2	3,0	2,3	2,5	3,5	3,3	3,3	3,7	4,0	-	4,5
	maksymalna	2,0	3,0	3,0	4,0	3,0	4,0	5,0	4,0	4,0	4,0	4,0	-	5,0

Źródło: opracowanie własne.

Tabela 6-6 Czas optymalizacji oraz łączny czas optymalizacji zagadnienia VRP z zależności od liczby klientów i poziomu konserwatywności.

Wariant	Liczba klientów													
	20	25	30	35	40	45	50	55	60	65	70	75	80	
Czas optymalizacji [s]	Odporny	0,86	2,45	4,15	11,89	28,06	23,69	59,15	42,01	84,69	126,83	300,08	-	282,41
	(1-alfa) = 65%	0,73	0,86	1,25	7,22	20,55	23,59	67,69	91,29	108,44	118,64	137,67	-	290,79
	(1-alfa) = 80%	0,41	1,18	1,60	3,17	8,29	22,07	47,94	49,22	65,89	66,91	155,53	-	165,16
	(1-alfa) = 95%	1,59	4,73	4,58	9,70	22,38	23,38	85,37	81,79	78,98	134,07	277,05	-	162,84
Łączny czas optymalizacji [s]	Odporny	38,53	56,85	80,58	113,05	171,90	212,69	278,62	349,32	432,46	758,56	1167,82	-	960,50
	(1-alfa) = 65%	30,85	52,16	67,39	103,18	148,21	175,67	246,98	340,92	424,08	498,47	638,54	-	966,66
	(1-alfa) = 80%	31,59	48,10	75,80	105,82	136,70	185,96	241,56	295,72	406,00	431,99	607,74	-	796,79
	(1-alfa) = 95%	29,13	192,26	244,21	273,19	146,45	451,33	604,24	799,25	1184,38	539,42	752,94	-	786,04

Źródło: opracowanie własne.

Ostatnia kwestia jaka została sprawdzona to jaki jest czas optymalizacji problemu VRP wykorzystującego dane ze stochastycznego problemu SPP, a jaki dla podejścia odpornego na wahania parametrów modelu. Czas ten jest przeciętnie krótszy o około 10% niż w podejściu odpornym (tabela 6-6). Warto jednak zwrócić uwagę na poprzedni wniosek o zwiększonej liczbie pojazdów. Jak to wskazano w podrozdziale 5.3.2, większa liczba tras jest ściśle zwią-

zana z czasem optymalizacji, zatem różnica ta jest wynikiem występowanie zwiększonej liczby tras w rozwiązaniu.


Drugi parametr odnoszący się do czasu to całkowity czas obliczeń, na który składa się również czas potrzebny na obliczenie najkrótszych ścieżek parami. Średnio czas ten jest większy dla wariantu stochastycznego o 16%, w odniesieniu do podejścia odpornego. Szczególny wzrost zapotrzebowania na czas, obserwowalny jest przy prawdopodobieństwie na poziomie 95%.

6.3.2 ANALIZA ZMIENNOŚCI ZNORMALIZOWANEJ WARTOŚCI FUNKCJI KRYTERIALNEJ DLA PODEJŚCIA STOCHASTYCZNEGO I ODPORNOŚCIOWEGO

W celu pogładowej prezentacji cech optymalizacji stochastycznej wykorzystującej model α -najkrótszej ścieżki wykonano ostatnią symulację, w której sprawdzono jak wartość funkcji celu modelu VRP zmienia się w zależności od poziomu prawdopodobieństwa i od stopnia losowego scenariusza. Analogicznie jak poprzednio obliczono serię rozwiązań stochastycznych, w których założono stopniowe zwiększania poziomu prawdopodobieństwa. Wartości parametru zmieniano z krokiem co 4% w zakresie⁴⁵ [51%;99%]. Dla każdego rozwiązania wygenerowano zestaw 50 losowych scenariuszy z założeniem stopniowego zwiększania udziału odchylenia standardowego w czasie przejazdu zgodnie z formułą (6.5). Jednakże zakres zmienności udziału odchylenia przyjęto szerszy tj. [0%; 300%] odchylenia standardowego. Przyjęcie szerszego zakresu badania wynika z korzystania w symulacjach z generatora losowych wartości funkcji gęstości rozkładu normalnego w oparciu o m.in. przyjęte prawdopodobieństwo. Tak więc, w przykładach testowych gdzie zakłada się poziom prawdopodobieństwa większy niż 95%, to rozrzut wartości czasu przejazdu może być bardzo wysoki. Jest to spowodowane cechą rozkładu normalnego - reguła trzech sigm. Zasada ta mówi o symetryczności funkcji gęstości, w której około 99,7% wartości cech leży w odległości mniejszej niż 3 odchylenia standardowe w obu kierunkach od wartości oczekiwanej. Dokładnie takiemu samemu testowi poddano rozwiązania podejścia odpornego uzyskane w analizie z poprzedniego podrozdziału.


Dla każdego zestawu 50 scenariuszy w obrębie jednego przykładu testowego obliczono średnią dla znormalizowanych wartości funkcji celu. Otrzymane wyniki zmienności znormalizowanej wartości funkcji kryterialnej modelu (n_{VRP2}) dla podejścia stochastycznego zaprezentowano na Rysunek 6.26. Charakterystykę zmienności funkcji celu dla podejścia odpornego zaprezentowano na Rysunek 6.27.

⁴⁵ Dla wartości $(1 - \alpha) < 0,51$ dystrybuanta rozkładu normalnego dla niektórych parametrów wartości średniej oraz odchylenia standardowego przyjmowała wartości ujemne, stąd analizę rozpoczęła od wartości powyżej 50%.



Rysunek 6.26 Wpływ zmiany prawdopodobieństwa wartości czasu przejazdu i stopnia realizacji danych na znormalizowaną wartość funkcji celu w podejściu stochastycznym.

Źródło: opracowanie własne.



Rysunek 6.27 Wpływ zmiany poziomu konserwatywności i stopnia realizacji danych na znormalizowaną wartość funkcji celu w podejściu odpornym.

Źródło: opracowanie własne.

Porównując powyższe wykresy do poprzednich (Rysunek 6.19 oraz Rysunek 6.20) można zaobserwować cechę: podejścia, które uwzględniają możliwość zmian parametrów modelu wygładzają przebieg funkcji celu modelu. Cecha ta jest bardzo ważną informacją szczególnie na etapie wyboru właściwej wartości parametru wpływającego na poziom zmienności, czyli poziomu prawdopodobieństwa oraz parametru konserwatywności. Wraz ze znajomością typowej charakterystyki przebiegu funkcji celu, konsekwencje wyboru nie do końca właściwej wartości tych parametrów mogą być nieduże.

W podejściu stochastycznym przyjmowanie wysokich wartości prawdopodobieństwa (powyżej 85%) wpływa na otrzymywanie rozwiązania o wysokim pesymizmie. Dla scenariuszy gdzie czas przejazdu w sieci jest w granicach jednego odchylenia standardowego, rozwiązania takie generują wysokie koszty, głównie w postaci czasu wczesnego przyjazdu. Dla scenariuszy nietypowych (przekraczających zakładany zakres) wartość funkcji celu maleje jed-

nak w odniesieniu do podejścia odpornego wartość jej jest wciąż większa. Efekt ten z kolei jest wynikiem większego czasu przejazdu (przez źle dobraną ścieżkę pomiędzy klientami). Dla mniejszych wartości prawdopodobieństwa (poniżej 85%) optymalizacja stochastyczna gwarantuje dobre rozwiązania, ale podobnie - w granicach zakładanych zmian. Scenariusze, w których występowały wysokie wahania od wartości oczekiwanej, koszt rozwiązania stochastycznego znacząco wzrastał. Jest to spowodowane zwiększaniem się czasu przejazdu oraz czasu opóźnienia.

Analizując przebieg funkcji dla podejścia odpornego zaprezentowanego na Rysunek 6.27 można zaobserwować podobieństwo zmienności do opisanej powyżej charakterystyki optymalizacji odpornej. Analogia ta występuje do pewnej wartości parametru konserwatyizmu I^{SP} . Powyżej tej wartości podejście odporne zapewnia stabilność rozwiązania pomimo wysokiej zmienności parametrów (tu 3-krotność zakładanego zbioru niepewności). Jest to podstawowa i najważniejsza cecha optymalizacji odpornej na wahania parametrów modelu.

6.4 WNIOSKI Z ROZDZIAŁU NR 6

W rozdziale wykonano serię testów w celu określenia charakterystyki proponowanego podejścia oraz oceny jakości rozwiązań otrzymanych w drodze optymalizacji zaproponowanego modelu wybranego problemu wyznaczania tras pojazdów w warunkach niepewności uwzględniając charakterystykę dystrybucji towarów w mieście. Otrzymane rozwiązania odniesiono do dwóch popularnych podejść: deterministycznego oraz stochastycznego.

Syntetyczne wnioski z tych analiz zaprezentowano w tabeli 6-7, w której symbolicznie oznaczono rodzaj potencjalnych korzyści i/lub strat. Przyjęto następujące znaczenie symboli:

- "+" - we wszystkich lub w zdecydowanej większości, podejście odporne wykazało pozytywne aspekty stosowania,
- "+/-" - w części przykładów testowych optymalizacja wykazuje potencjalne zyski, a w części potencjalne straty,
- "=" - nie można wskazać korzystniejszego wariantu (wyniki porównywalne),
- "-" - we wszystkich lub w zdecydowanej większości podejście odporne wykazało negatywne efekty stosowania.

Stosowanie optymalizacji odpornej na wahania parametrów wykazuje swoje zalety przede wszystkim w trzech parametrach oceniających: czas przejazdu, czas opóźnienia oraz liczba opóźnień. Z punktu widzenia firmy transportowej wyniki te mogą być dość interesującym aspektem, szczególnie, że w większości przypadków zyski te nie są uzyskiwane kosztem pogorszenia wartości pozostałych parametrów. W niektórych przypadkach testowych zyski te są ponoszone przez: wydłużenie długości tras (średnio o 2,3% dla deterministycznego odniesienia i 6,3% dla stochastycznego odniesienia) lub zaplanowanie harmonogramu odwiedzania klientów ze zwiększonym czasem oczekiwania. Ważnym jest również fakt, że liczba utworzonych tras w rozwiązaniu nie zmienia się istotnie.

Oprócz wspomnianych aspektów została wykazana bardzo ważna cecha optymalizacji odpornej na wahania parametrów w problemach VRP - zapewnienie stabilności rozwiązania nawet po przekroczeniu założonych wartości zmienności losowych parametrów. Własność ta

jest szczególnie ważna przy realizacji rozwiązań w wysoce dynamicznym, losowym i nieprzewidywalnym środowisku, jakim jest ruch drogowy w mieście.

Tabela 6-7 Syntetyczne porównanie podejścia odpornego na wahania parametrów modelu z podejściem deterministycznym oraz z stochastycznym.

Lp.	Parametr oceniający	Odniesienie: Wariant deterministyczny			Odniesienie: Wariant stochastyczny:		
		Gamma 5	Gamma 20	Gamma maks.	(1-alfa) = 65%	(1-alfa) = 80%	(1-alfa) = 95%
1	Czas przejazdu	+	+	+	+	+	+/-
2	Dystans	+/-	+/-	+/-	+/-	+/-	+/-
3	Czas wczesnego przyjazdu	-	-	-	-	+/-	+
4	Czas opóźnienia	+	+	+	+	+	+
5	Liczba tras	=	=	=	-	-	+/-
6	Liczba wczesnych przyjazdów	-	-	-	-	+/-	+
7	Liczba opóźnień	+	+	+	+	+	+
8	Czas optymalizacji	=	=	=	+/-	+/-	+/-
9	Łączny czas optymalizacji	+/-	+/-	+/-	+/-	+/-	+/-

Źródło: opracowanie własne.

7 PODSUMOWANIE I WNIOSKI

7.1 SPEŁNIENIE ZAŁOŻONYCH CELÓW ORAZ WERYFIKACJA POSTAWIONEJ TEZY

Niniejsza rozprawa doktorska poświęcona jest tematyce planowania tras pojazdów w warunkach miejskich z uwzględnieniem niepewności wartości czasu przejazdu. Głównym celem pracy było zaproponowanie metodyki rozwiązywania zagadnień wyznaczania tras pojazdów, w których została uwzględniona niepewność czasów przejazdów w sieci drogowej miasta. Celami pośrednimi było zdefiniowanie autorskiego, matematycznego modelu problemu wyznaczania tras pojazdów, analiza jego charakterystyki oraz przedstawienie koncepcji umiejscowienia problematyki wyznaczania tras pojazdów w podejściu systemowym.

W kontekście rzeczywistego procesu dystrybucji towarów w mieście pożądanym jest, aby wyznaczone trasy pojazdów, posiadały cechę niskiej wrażliwości na zmiany wartości parametrów ruchu drogowego. Jest to spowodowane przede wszystkim przez: wieloaspektowy, negatywny wpływ transportu towarów na otoczenie i na uczestników systemu transportowo - logistycznego miasta oraz charakterystykę miejskiego ruchu drogowego - dynamizm, losowość, nieokreśloność incydentów. Niewłaściwe zaplanowanie przebiegu tras może powodować dłuższe przebywanie pojazdów w sieci drogowej miasta oraz pogarszać jakość świadczonych usług. Aspekty te zostały zauważone m.in. w raportach Unii Europejskiej, które rekomendują stosowanie metod do planowania tras w mieście, jako rozwiązanie o niskim koszcie wdrożenia i dobrych efektach funkcjonowania.

Uwzględniając wyniki analizy wpływu dystrybucji towarów w miastach, charakterystyki miejskiego ruchu drogowego oraz rekomendacji w raportach o miejskim transporcie towarów, dalsze badania ukierunkowano na stworzenie modelu matematycznego problemu wyznaczania tras pojazdów, który uwzględniałby niepewność wartości parametrów modelu. W oparciu o szeroki przegląd literatury rozpoznano dwie metodyki modelowania zmienności parametrów: podejście stochastyczne i odpornościowe. Na podstawie analizy charakterystyki i założeń obu metodyk oraz adekwatności stosowania do opisu zmienności ruchu drogowego w mieście, podjęto próbę implementacji założeń teorii optymalizacji odpornościowej w problematyce wyznaczania tras pojazdów. W kolejnym, szczegółowym rozpoznaniu literatury, dokonano identyfikacji braków w dotychczasowych badaniach nad zastosowaniem optymalizacji typu "robust" w zagadnieniach układania tras pojazdów, szczególnie na obszarach miejskich.

Na podstawie przeprowadzonych wywiadów z firmami transportowymi oraz przeglądu literatury określono specyfikacje i założenia do modelu wybranego problemu (kryteria, ograniczenia). W ten sposób został stworzony autorski matematyczny model dla problemu wyznaczania tras pojazdów, który uwzględnia elastyczne okna czasowe u klientów, przepływy rewersyjne towarów oraz zależność danych od czasu. Zdefiniowano dwie odmiany modelu dla

problemu wyznaczania tras pojazdów: czterokryterialną oraz pięciokryterialną. Na bazie takich modeli rozważono jaka byłaby interpretacja przyjętych założeń modelu, gdyby zostały wprowadzone warunki o losowości wartości czasu przejazdu przez sieć drogową. Na podstawie otrzymanych wniosków zaproponowano metodę upraszczającą poziom złożoności modelu. Dzięki zaproponowanej metodzie upraszczającej możliwe było wprowadzenie losowej niepewności zmienności czasu przejazdu w sieci drogowej w modelu bez istotnego wpływu jej na czas obliczeń. Jako podstawowy element modelowania losowej zmienności parametrów modelu przyjęto założenia określone przez teorię optymalizacji odpornej na wahania parametrów modelu. W pracy zaproponowano implementację tych założeń przez dekompozycję problemu wyznaczania tras pojazdom uwzględniającego zmienność parametrów na dwa prostsze zagadnienia: dwukryterialny odporny problem najkrótszej ścieżki zależny od pory dnia oraz wielokryterialny deterministyczny problem wyznaczania tras pojazdów.

Odnosząc się do aktualnego stanu wiedzy jest to pierwsza praca, która przedstawia metodykę modelowania niepewności czasu przejazdu w zagadnieniach wyznaczania tras pojazdów, w której uwzględniono: wybrane rzeczywiste warunki dystrybucji, charakterystykę miejskiej sieci drogowej, wielokryterialność celu, zależność modelu od czasu, elastyczne okna czasowe obsługi klientów oraz wsteczne przepływy towarów. Dodatkowo proponowana metoda została porównana do powszechnie rozważanych podejść: deterministycznego i stochastycznego. Jak pokazują wyniki symulacji komputerowych, występujące w literaturze przedmiotu stwierdzenia o słabych stronach stosowania podejścia stochastycznego przy uwzględnianiu losowej zmienności ruchu drogowego, w przypadku procesu przewozu ładunków zostały potwierdzone. Pomimo, że oba podejścia modelują procesy losowe, teoria optymalizacji odpornej wykazuje lepsze rezultaty niż optymalizacja stochastyczna. Do oceny wybrano dziewięć parametrów oceniających dane rozwiązanie. Charakterystyka ruchu drogowego została określona przez wykorzystanie symulatora ruchu drogowego, a charakterystyka klientów została stworzona w oparciu o informacje uzyskane w wywiadzie z firmą transportowo - logistyczną. Otrzymane wyniki z modelu symulacyjnego zostały odniesione do rzeczywistych przekrojowych pomiarów ruchu, dzięki czemu model uzyskał statystyczną zgodność z rzeczywistą siecią drogową. Wykorzystanie danych do symulacji opartych o rzeczywiste warunki jest kolejny to element, który wyróżnia pracę na tle innych badań.

Dodatkowo w pracy zaprezentowano koncepcję ujęcia problemu wyznaczania tras w ujęciu systemowym, który został oparty o strukturę Inteligentnych Systemów Logistycznych. Takie spojrzenie na problem procesu rozwożenia i zbierania towarów z dowolnych lokalizacji w mieście, umożliwia identyfikację funkcjonalnych połączeń z pozostałymi elementami systemu logistycznego miasta.

Wobec powyższego, według autora, wszystkie cele pracy zostały zrealizowane.

Na podstawie przeprowadzonych analiz i eksperymentów komputerowych dowiedziono, że założenia optymalizacji typu "robust" zastosowane w problematyce wyznaczania tras pojazdów są lepszą reprezentacją losowej zmienności czasu przejazdu przez sieć niż aktualnie stosowane podejścia. Weryfikacja charakterystyki proponowanego podejścia została dokonana w oparciu o poddawanie otrzymanych rozwiązań serii losowych testów, które mają symulować zmienną losowość parametrów ruchu drogowego. Dla przykładu w stosunku do podejścia deterministycznego średnio czas przejazdu pojazdów przez sieć drogową zmniejszył się o

3% (maksymalny odnotowany zysk 14%), a w odniesieniu do optymalizacji stochastycznej czas ten zmniejszył się o 9% (maksymalnie 14%). Redukcja ta oznacza krótszy czas uczestnictwa pojazdu w ruchu miejskim, co za tym idzie mniejszy jego wpływ na otoczenie oraz krótszy czas pracy kierowców. Drugi ważny parametr to czas opóźnienia rozpoczęcia obsługi klienta przez kierowcę. Dla rozwiązania deterministycznego zyski wynoszą średnio około 12 minut na jednego klienta, a dla wariantu stochastycznego różnice wynoszą średnio 7 minut na klienta (maksymalnie 22 minuty) na korzyść optymalizacji odpornej. Bardzo ważną cechą jest fakt, że otrzymane zyski nie są otrzymywane w drodze proporcjonalnego pogorszenia pozostałych parametrów.

Dowodzono, że model stochastyczny problemu wyznaczania tras jest właściwy tylko w założonych zakresach zmienności i w założonym stopniu losowości. W wariantach, w których wahania czasu przejazdu są większe niż założono to w modelu, rozwiązanie charakteryzuje się zbędnymi kosztami - głównie w postaci czasu przejazdu, czasu opóźnienia u klientów oraz liczby późnych klientów. Podejście deterministyczne, z uwagi na swoje podstawowe założenia o braku zmienności parametrów modelu, wykazuje się najgorszymi rezultatami oraz niską praktycznością stosowania.

Ponadto dowiedziono, że w przypadku niewłaściwego zaplanowania zakresu zmienności czasu przejazdu w procesie planowania tras pojazdów, proponowane podejście charakteryzuje się stabilizacją rozwiązania. Jest to bardzo istotna informacja dla praktycznego wdrożenia podejścia, ponieważ przy zmiennych warunkach ruchowych rozwiązania oparte o proponowaną metodykę nie generują nagłych skoków w wartości ponoszonych kosztów (np. czas operacyjny pojazdów).

Wobec powyższego, według autora, wszystkie tezy pracy zostały potwierdzone.

7.2 WNIOSKI I DISKUSJA WYNIKÓW

Na podstawie zaprezentowanych wyników w pracy można przedstawić następujące wnioski podsumowujące przeprowadzone badania i symulacje komputerowe:

- Przyjmowanie założeń deterministycznych w rzeczywistej dystrybucji towarów w warunkach miejskich nie ma żadnego uzasadnienia,
- Wysoce zmienny element systemu transportowego, jakim jest ruch drogowy determinuje stosowanie podejść, w których zakłada się zmienność i nieokreśloność parametrów modelu, szczególnie dla problemu wyznaczania tras pojazdów,
- Niezależnie od stosowania podejścia stochastycznego czy odpornego na wahania parametrów, cechą charakterystyczną tych metod jest stabilizacja rozwiązań, tzn. nieduży błąd związany z nietrafionym doбором prawdopodobieństwa lub parametru konserwatywności nie generuje znacznego wzrostu kosztów realizacji tras pojazdów,
- Pesymistyczne podejście zakładające maksymalną potencjalną zmianę z czasie przejazdu w sieci drogowej dla problemu marszrutyzacji jest podejściem niosącym jednocześnie wysokie potencjalne zyski oraz straty w kosztach realizacji tras,
- Stosowanie podejścia stochastycznego jest właściwe tylko w warunkach zmienności określonej: zakładanym rozkładem prawdopodobieństwa oraz zakresem tej zmienności

ści. Nietypowa zmienność parametrów może generować zbędne koszty realizacji tras przewozu ładunków w mieście,

- Tylko podejście odporne na wahania parametrów modelu gwarantuje dobrą jakość rozwiązania dla zjawisk typowych oraz nietypowych, przekraczających zakładany zakres i sposób zmienności,
- Podejście odporne na zmiany w problematyce wyznaczania tras pozytywnie wpływa na czas opóźnienia u klientów oraz w większości przypadków na czas przejazdu pojazdów przez sieć drogową. Zyski te nie odbywają się kosztem zwiększenia liczby tras,
- Koszt uodpornienia rozwiązania na wahania parametrów odbywa się przez nieznaczne zwiększenia długości tras (średnio około 2%) oraz czasu wcześniejszego przyjazdu (średnio o 2,5 minuty więcej na jednego klienta),
- Niewłaściwe dobranie parametru konserwatywności I^{SP} (zbyt małe), nie powoduje ponoszenia potencjalnych strat w odniesieniu do podejścia deterministycznego; zmniejsza potencjalne zyski,
- W większości analizowanych parametrów potencjalne zyski/straty są uzależnione od liczebności klientów.

Wnioski dotyczące zaproponowanej metody dekompozycji oraz implementacji niepewności w problematyce wyznaczania tras pojazdów:

- Zaproponowana metoda dekompozycji problemów wyznaczania tras pojazdów realizowanych w rzeczywistych miejskich sieciach drogowych umożliwia uproszczenie poziomu złożoności skomplikowanych sformułowań rzeczywistej dystrybucji towarów,
- Pomimo stosowania metody dokładnej do optymalizacji zaproponowane podejście jest potencjalnie możliwe do wykorzystania przez firmy transportowe realizujące usługi na terenach miejskich,
- Zaproponowany model wyznaczania tras jest dość szerokim uogólnieniem różnych odmian tego zagadnienia. Uwzględnia on przepływy wsteczne towarów, elastyczne okna czasowe oraz pięć kryteriów poszukiwania rozwiązania.
- Odpowiedni dobór parametru konserwatywności rozwiązania powinno odbywać się po zdobyciu tzw. wiedzy eksperckiej; wiedza ta może być sformalizowana w postaci bazy wiedzy wykorzystywanej przez inteligentne systemy wspomaganie decyzji,
- Wprowadzenie zmienności parametrów modelu VRP zdefiniowanej przez niepewność danych nie wpływa na czas poszukiwania rozwiązania, dzięki zaproponowanemu podejściu integracji odpornego problemu najkrótszej ścieżki z zagadnieniem VRP,
- Przeniesienie cechy uodpornienia na proces obliczania najkrótszych ścieżek posiada cechę uniwersalnego podejścia do wszystkich odmian problemu wyznaczania tras. Po obliczeniu odpornych na wahania ścieżek możliwe jest zastosowanie dowolnego rodzaju problemu wyznaczania tras pojazdów.

7.3 KIERUNKI DALSZYCH BADAŃ

W pracy podjęto próbę matematycznego opisu procesu dystrybucji towarów w miastach uwzględniając niepewność parametrów ruchu drogowego oraz określenie jego potencjalnych zalet i wad. Pomimo przyjęcia wielu rzeczywistych aspektów oraz aktualnego stanu wiedzy, rozważane zagadnienie nadal nie jest w pełni rozwiązane, zaprezentowane badania w tej pracy można rozwijać w wielu kierunkach, takich jak:

1. Weryfikacja osiągniętych rezultatów w rzeczywistym procesie transportowym na terenach miejskich,
2. Określenie potencjalnych strat i zysków dla innych odmian problemu wyznaczania tras,
3. Wprowadzenie metod heurystycznych do rozwiązywania zadania wyznaczania tras pojazdów w celu zwiększenia użyteczności modelu,
4. Budowa inteligentnego narzędzia do tworzenia i aktualizacji bazy danych dotyczących odpornych ścieżek pomiędzy klientami uwzględniającego dane aktualne i historyczne w celu zmniejszenia czasu obliczeń potrzebnego na wyznaczenie wszystkich połączeń pomiędzy lokalizacjami klientów,
5. Wykonanie analiz dotyczących sposobu definiowania zbiorów niepewności określających losowość parametrów modelu wraz z ich wpływem na jakość rozwiązań zagadnień wyznaczania tras pojazdów.

BIBLIOGRAFIA

- [1] A. Adamski, "Advanced system platform HILS for development of ILS systems," *Logistyka*, no. 6, pp. 1331-1339, 2014.
- [2] A. Adamski, "Hierarchical Integrated Intelligent Logistics System Platform," *Procedia - Social and Behavioral Sciences*, no. 20, pp. 1004–1016, 2011.
- [3] A. Adamski, "IILS: Intergrated Intelligent Logistics Systems," in *Cracow University of Technology Logistics Conference*, Kraków, 2006, pp. 25-38.
- [4] A. Adamski, *Inteligentne systemy transportowe: sterowanie, nadzór i zarządzanie*. Kraków: Wydawnictwo AGH, 2003.
- [5] A. Adamski, "Routing problems based on HILS system platform," *LogForum*, vol. 11, no. 1, pp. 87-98, 2015.
- [6] A. Adamski and D. Kubek, "HITS: Advanced City Logistics Systems," in *Human Factor of s Global Society: a System of Systems Perspective.*: CRC Press, 2014, pp. 17-30.
- [7] A. Adamski and D. Kubek, "VRP-R: Robust routing problems solutions based on the HILS platform," *Logistyka*, no. nr 6, 2014.
- [8] A. Agra et al., "The robust vehicle routing problem with time windows," *Computers & Operations Research*, vol. 40, no. 3, pp. 856–866, 2013.
- [9] *Aimsun 8 Dynamic Simulator User's Manual*, 2014.
- [10] *Aimsun 8 Macroscopic Modelling Manual*, 2013.
- [11] T. Ambroziak and R. Jachimowski, "Algorytm klasteryzacji w zastosowaniu do problemu trasowania pojazdów," *Logistyka*, no. nr 2, 2012.
- [12] T. Ambroziak and R. Jachimowski, "Wybrane aspekty zagadnienia okien czasowych w problemie trasowania pojazdów," *Automatyka / Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie*, vol. 15, no. 2, pp. 51-59, 2011.
- [13] B. Anbaroglu, B. Heydecker, and Cheng T., "Spatio-temporal clustering for non-recurrent traffic congestion detection on urban road networks," *Transportation Research Part C*, no. 48, pp. 47-65, 2014.
- [14] E. Angelelli and M.G. M.G. Speranza, "The Periodic Vehicle Routing Problem with Intermediate Facilities," *European Journal of Operational Research*, pp. 233-247, 2002.
- [15] L. Bach, G. Hasle, and S. Wøhlk, "A lower bound for the Node, Edge and Arc Routing Problem," *Computers & Operations Research*, vol. 40, pp. 943–952, 2013.
- [16] M. Balinski and R. Quandt, "On an integer program for a delivery problem," *Operations Research*, no. 12, pp. 300-304, 1964.
- [17] D. Barbucha, "A cooperative population learning algorithm for vehicle routing problem with time windows," *Neurocomputing*, no. 146, pp. 210-229, 2014.
- [18] D. Barbucha, "Search modes for the cooperative multi-agent system solving the vehicle routing problem," *Neurocomputing*, vol. 88, pp. 13-23, 2012.
- [19] D. Barbucha, I. Czarnowski, P. Jędrzejowicz, E. Ratajczak, and I. Wierzbowska, "JADE-based A-team as a tool for implementing population-based algorithms," *Proceedings - ISDA 2006: Sixth International Conference on Intelligent Systems Design and Applications*, no. 3, pp. 144-149, 2006.
- [20] D. Barbucha and P. Jędrzejowicz, "Multi-agent platform for solving the dynamic vehicle routing problem," *IEEE Conference on Intelligent Transportation Systems*, pp. 517-522, 2008.
- [21] BazTech. BazTech. [Online]. <http://baztech.icm.edu.pl/>
- [22] A. Ben-Tal, L. El Ghaoui, and A. Nemirovski, "Robust optimization". New Jersey: Princeton University Press, 2009.

- [23] A. Ben-Tal and A. Nemirovski, "Robust solutions of Linear Programming problems contaminated with uncertain data," *Mathematical Programming*, vol. 88, no. 3, pp. 411-424, 2008.
- [24] R. Bent and P. Van Hentenryck, "A two-stage hybrid local search for the vehicle routing problem with time windows," *Transportation Science*, vol. 38, no. 4, pp. 515-530, 2004.
- [25] D.J. Bertsimas, "A vehicle routing problem with stochastic demands," *Operations Research*, vol. 40, no. 3, pp. 574-585, 1992.
- [26] D. Bertsimas, D.B. Brown, and C. Caramanis, "Theory and Applications of Robust Optimization," *SIAM Review*, vol. 53, no. 3, pp. 464-501, 2008.
- [27] D. Bertsimas and M. Sim, "Price of Robustness," *Operations Research*, vol. 54, no. 1, pp. 150-168, 2004.
- [28] D. Bertsimas and M. Sim, "Robust discrete optimization and network flows," *Mathematical Programming*, vol. 98, pp. 49-71, 2003.
- [29] BESTUFS II, "Best Urban Freight Solutions II : Quantification of Urban Freight Transport Effects I ," 2006.
- [30] BESTUFS, "Przewodnik po dobrych praktykach w towarowym transporcie miejskim," 2006.
- [31] L. Bianchi, M. Dorigo, L. M. Gambardella, and W. J. Gutjahr, "A survey on metaheuristics for stochastic combinatorial optimization," *Natural Computing*, vol. 8, no. 2, pp. 239-287, 2009.
- [32] Biuro Infrastruktury Miasta, "Nowy plan dystrybucji towarów w Krakowie - CARAVEL Działanie 10.3," Kraków, 2008.
- [33] J. Brandão, "A new tabu search algorithm for the vehicle routing problem with backhauls," *European Journal of Operational Research*, vol. 173, no. 2, pp. 540-555, 2006.
- [34] S.R. Cardoso, A.P. Barbosa-Povoa, and S. Relvas, "Design and planning of supply chains with integration of reverse logistics activities under demand uncertainty," *European Journal of Operational Research*, vol. 226, pp. 436-451, 2013.
- [35] I. Celiński, "Zastosowanie wideodetekcji ruchu pojazdów do walidacji i kalibracji modeli sieci drogowej," *Prace naukowe Politechniki Warszawskiej*, no. z.95, 2013.
- [36] X. Chen, M. Sim, and P. Sun, "A Robust Optimization Perspective on Stochastic Programming," *Operations Research*, vol. 55, no. 6, pp. 1058-1071, 2007.
- [37] J. Chodur and K. Ostrowski, "Charakterystyka strumienia ruchu w początkowym okresie sygnału zielonego na skrzyżowaniu z sygnalizacją," *Transport Miejski i Regionalny*, no. 5, pp. 3-9, 2012.
- [38] K. Chwesiuk, "Wybrane aspekty logistyki miejskiej," *Prace Naukowe Transport*, no. z. 60, 2007.
- [39] CIVITAS CARAVEL. [Online]. <http://www.caravel.forms.pl/>
- [40] E. Codina and J. Barceló, "Adjustment of O-D matrices from observed volumes: an algorithmic approach based on conjugate gradients," *European Journal of Operations Research*, no. 155, pp. 535-557, 2004.
- [41] W., Buisson, C., Hoogendoorn and S.P. Daamen, "Traffic simulation and data. Validation methods and applications". Boca Raton: CRC Press, 2015.
- [42] L. Dablanc, "Goods transport in large European cities: Difficult to organize, difficult to modernize," *Transportation Research Part A*, no. 41, pp. 280-285, 2007.
- [43] G. Dantzig and J. Ramser, "The truck dispatching problem," *Management Science*, no. 6, pp. 80-91, 1959.
- [44] N. Dasburg and J. Schoemaker. (2006) BESTUFS II: Quantification of Urban Freight Transport Effects II.
- [45] Deloitte Polska. "Raport o korkach w 7 największych miastach Polski: Warszawa, Łódź, Wrocław, Kraków, Katowice, Poznań, Gdańsk", 2004.
- [46] A. Deng, C. Mao, and Y. Zhou, "Optimizing Research of an Improved Simulated Annealing Algorithm to Soft TimeWindows Vehicle Routing Problem with Pick-up and Delivery," *Systems Engineering — Theory & Practice*, vol. 29, no. 5, pp. 186-192, 2009.
- [47] Design Manual for Roads and Bridges (DMRB), 1996.
- [48] A.V. Donati, R. Montemanni, N. Casagrande, A.E. Rizzoli, and L.M. Gambardella, "Time dependent

- vehicle routing problem with a multi ant colony system," *European Journal of Operational Research*, no. 185, pp. 1174–1191, 2008.
- [49] A.V. Donati, R. Montemanni, L.M. Gambardella, and A.E. Rizzoli, "Integration of a robust shortest path problem with a time dependent vehicle routing model and applications," in *CIMSA 2003 - International Symposium on Computational Intelligence for Measurement Systems and Applications Lugano, Switzerland*, 29-31 July 2003, Lugano, 2003.
- [50] M. Dror, G. Laporte, and P. Trudeau, "Vehicle routing with split deliveries," *Discrete Applied Mathematics*, vol. 50, no. 3, pp. 239–254, 1994.
- [51] C. Duhamel, P. Lacomme, C. Prodhon, and C. Prins, "A GRASP×ELS approach for real-life Location Routing Problems," *Computers & Industrial Engineering*, 2009. *CIE 2009. International Conference on*, pp. 1082-1087, 2009.
- [52] L. El Ghaoui. "Robust Optimization and Applications". [Online]. <http://www.eecs.berkeley.edu/~elghaoui/Talks/talkIMA2003b.pdf>
- [53] N.A El-Sherbeny, "Vehicle routing with time windows: An overview of exact, heuristic and metaheuristic methods," *Journal of King Saud University - Science*, vol. 22, no. 3, pp. 123–131, 2010.
- [54] S. Erdogan and E. Miller-Hooks, "A Green Vehicle Routing Problem," *Transportation Research Part E*, vol. 48, pp. 100–114, 2012.
- [55] M.A. Figliozzi, "The time dependent vehicle routing problem with time windows: Benchmark problems, an efficient solution algorithm, and solution characteristics," *Transportation Research Part E*, no. 48, pp. 616–636, 2012.
- [56] W. Findeisen, J. Szymanowski, and A. Wierzbicki, "Teoria i metody obliczeniowe optymalizacji". Warszawa: PWN, 1980.
- [57] G. Fleury, P. Lacomme, and C. Prins, "Evolutionary Algorithms for Stochastic Arc Routing Problems," *Applications of Evolutionary Computing*, vol. 3005, pp. 501-512, 2004.
- [58] M. Florian and Y. Chen, "Coordinate Descent Method for the Bi-level O/D Matrix Adjustment Problem," *International Transactions in Operations Research*, vol. 2, no. 2, pp. 165-175, 1955.
- [59] (2015, Oct.) FRAME. The European ITS Framework Architecture. [Online]. www.frame-online.net
- [60] S. Gaca, W. Suchorzewski, and M. Tracz, "Inżynieria ruchu drogowego. Teoria i praktyka". Warszawa: Wydawnictwa Komunikacji i Łączności, 2014.
- [61] Y. Gao, "Shortest path problem with uncertain arc lengths," *Computers and Mathematics with Applications*, no. 62, pp. 2591–2600, 2011.
- [62] G. Giuliano, T. O'Brien, L. Dablanc, and K. Holliday, "NCFRP REPORT 23: Synthesis of Freight Research in Urban Transportation Planning," Waszyngton, 2013.
- [63] Główny Urząd Statystyczny. "Transport. Wyniki działalności w 2013 roku", GUS 2014
- [64] M. Goetschalckx and C. Jacobs-Blecha, "The vehicle routing problem with backhauls," *European Journal of Operational Research*, vol. 42, no. 1, pp. 39–51, 1989.
- [65] J. Goh and M. Sim, "Distributionally Robust Optimization and Its Tractable Approximations," *OPERATIONS RESEARCH*, vol. 58, no. 4, pp. 902–917, 2010.
- [66] J. Goh and M. Sim, "Robust Optimization Made Easy with ROME," *Operations Research*, vol. 59, no. 4, pp. 973-985, 2011.
- [67] L. Gouveia, "A result on projection for the vehicle routing problem," *European Journal of Operational Research*, vol. 85, pp. 610-624, 1995.
- [68] J. Han, C. Lee, and S. Park, "A Robust Scenario Approach for the Vehicle Routing Problem with Uncertain Travel Times," *Transportation Science*, vol. 48, no. 3, pp. 373-390, 2014.
- [69] H. Hashimotoa, T. Ibarakib, S. Imahoric, and M. Yagiuraa, "The vehicle routing problem with flexible time windows and traveling times," *Discrete Applied Mathematics*, vol. 154, pp. 2271 – 2290, 2006.
- [70] Interaktywnie.com. (2013) E-COMMERCE - Raport. [Online]. <http://interaktywnie.com>

- [71] R. Jachimowski and T. Ambroziak, "Klasteryzacja punktów obsługi i wyznaczanie tras pojazdów w dwuszczeblowym systemie dystrybucji," *Logistyka*, no. nr 4, 2012.
- [72] R. Jadczyk, "Rozwiązywanie zagadnień układania tras pojazdów z wykorzystaniem algorytmów ewolucyjnych," *Badania Operacyjne i Decyzje*, no. nr 3-4, pp. 7-22, 2005.
- [73] A. Jaskiewicz and P. Kominek, "Genetic local search with distance preserving recombination operator for a vehicle routing problem," *European Journal of Operational Research*, no. 151 (2), 2003.
- [74] N. Jozefowicz, F. Semet, and E-G. Talbi, "Parallel and Hybrid Models for Multi-objective Optimization: Application to the Vehicle Routing Problem," in *PPSN VII, LNCS 2439*.: Springer-Verlag, 2002, pp. 271-280.
- [75] R. S. Jurecki, M. Jaśkiewicz, M. Guzek, Z. Lozia, and P. Zdanowicz, "Driver's reaction time under emergency braking a car – Research in a driving simulator," *Eksploatacja i Niezawodność*, vol. 14, no. 4, pp. 295-301, 2012.
- [76] O.E. Karasan, M.C. Pinar, and H. Yaman, "The robust shortest path problem with interval data," *Computers & Operation Research*, 2002.
- [77] B. Kim, S. Kimb, and S. Sahoob, "Waste collection vehicle routing problem with time windows," *Computers & Operations Research*, vol. 33, pp. 3624–3642, 2006.
- [78] Y. P. Kondratenko, S. B. Encheva, and E. V. Sidenko, "Synthesis of intelligent decision support systems for transport logistics," in *Intelligent Data Acquisition and Advanced Computing Systems (IDAACS)*, 2011 IEEE 6th International Conference, Praga, 2011, pp. 642-646.
- [79] Y. Kristianto, A. Gunasekaran, P. Helo, and M. Sandhu, "A decision support system for integrating manufacturing and product design into the reconfiguration of the supply chain networks," *Decision Support Systems*, no. 52, pp. 790–801, 2012.
- [80] D. Kubek, "Charakterystyka optymalizacji odpornej problemu najkrótszej ścieżki w obszarach zurbanizowanych," in *Metody i zastosowania badań operacyjnych*. Katowice: Studia Ekonomiczne Uniwersytetu Ekonomicznego w Katowicach, 2015.
- [81] D. Kubek, "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.
- [82] D. Kubek, "Wyznaczanie odpornych ścieżek w warunkach miejskich," *Logistyka*, no. nr 4, pp. 3965-3971, 2014.
- [83] D. Kubek, "Wyznaczanie tras typu "robust" pojazdów logistyki miejskiej," *Logistyka*, no. nr 3, pp. 3469-3470, 2014.
- [84] P. Lacomme, C. Prins, and W. Ramdane-Cherif, "Competitive memetic algorithms for arc routing problems," *Annals of Operations Research*, vol. 131, pp. 159–185, 2004.
- [85] P. Lacomme, C. Prins, and M. Sevaux, "A genetic algorithm for a bi-objective capacitated arc routing problem," *Computers & Operations Research*, vol. 33, pp. 3473–3493, 2006.
- [86] (2016, Mar.) LaMiLo. [Online]. <http://www.lamiloproject.eu/>
- [87] G. Laporte, F. Louveaux, and H. Mercure, "The vehicle-routing problem with stochastic travel-times," *Transportation Science*, vol. 26, no. 3, pp. 161-170, 1992.
- [88] G. Laporte, Y. Nobert, and S. Taillefer, "Solving a Family of Multi-Depot Vehicle Routing and Location-Routing Problems," *Transportation Science*, vol. 22, no. 3, pp. 161 - 172, 1988.
- [89] H.C. Lau, M. Sim, and K.M. Teo, "Vehicle Routing Problem with Time Windows and a Limited Number of Vehicles," *European Journal of Operational Research*, vol. 148, pp. 559-569, 2003.
- [90] K. Lewandowski, "Problemy zaopatrzenia punktów handlowych w centrach miast- wyniki badań ankietowych programu DORED," *Logistyka*, no. 2, pp. 853-863, 2012.
- [91] K. Lewandowski et al., "Pilotażowe badania programu DORED," *Logistyka*, no. 2, pp. 62-64, 2005.
- [92] Z. Li and A.C. Floudas, "Robust counterpart optimization: uncertainty sets, formulations and probabilistic guarantees," in *Proceedings of the 6th conference on Foundations of Computer-Aided Process Operations*,

- Savannah, 2012.
- [93] F. Li, B. Golden, and E. Wasil, "Very large-scale vehicle routing: new test problems, algorithms, and results," *Computers & Operations Research*, vol. 32, no. 5, pp. 1165–1179, 2005.
- [94] S. Lin and B.W. Kernighan, "An effective heuristic for the traveling salesman problem," *Operations Research*, no. 21, pp. 498–516, 1973.
- [95] W. Liu, "Uncertain programming models for shortest path problem with uncertain arc lengths," *Proceedings of the First International Conference on Uncertainty Theory*, pp. 148–153, 2010.
- [96] C. Malandraki and M.S. Daskin, "Time dependent vehicle routing problems: formulations, properties and heuristics algorithms," *Transportation Science*, vol. 26, no. 3, pp. 185 - 200, 1992.
- [97] MDS Transmodal Limited, "Study on urban freight transport - final report," 2012.
- [98] A. Mehmood and Easa S.M., "Modeling Reaction Time in Car-Following Behavior Based on Human Factors," *International Journal of Civil, Environmental, Structural, Construction and Architectural Engineering*, vol. 3, no. 9, 2009.
- [99] E. Michłowicz, "Rozwiązywanie problemów dostaw w systemach dystrybucji," *Logistyka*, no. nr 4, 2012.
- [100] L. Mingyong and C. Erbao, "An improved differential evolution algorithm for vehicle routing problem with simultaneous pickups and deliveries and time windows," *Engineering Applications of Artificial Intelligence*, vol. 2, pp. 188-195, 2010.
- [101] R. Montemanni and L.M. Gambardella, "An exact algorithm for the robust shortest path problem with interval data," *Computers & Operations Research*, no. 31, pp. 1667–1680, 2004.
- [102] R. Montemanni, L.M. Gambardella, and A.V. Donati, "A branch and bound algorithm for the robust shortest path problem with interval data," *Operations Research Letters*, vol. 32, pp. 225 – 232, 2004.
- [103] NETLIB. [Online]. <http://www.netlib.org/>
- [104] OECD, "Delivering the goods - 21st century challenges to urban goods transport," Paryż, 2003.
- [105] I.H. Osman and N.A. Wassan, "A reactive tabu search meta-heuristic for the vehicle routing problem with back-hauls," *JOURNAL OF SCHEDULING*, vol. 5, no. 4, pp. 263-285, 2002.
- [106] K. Ostrowski, "Analiza zachowań kierujących pojazdami w stanach nasycenia ruchem na wlotach skrzyżowań z sygnalizacją świetlną," *Logistyka*, no. 3, 2011.
- [107] B. Pawłowska, "Zewnętrzne koszty transportu, problemy ekonomicznej wyceny". Gdańsk: Wydawnictwo Uniwersytetu Gdańskiego, 2000.
- [108] J. Pempera, "Równoległy algorytm tabu z elementami inspirowanymi naturą dla problemu planowania tras," *Automatyka / Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie*, vol. 15, no. 2, pp. 399-408, 2011.
- [109] D. Pisinger and S. Ropke, "A general heuristic for vehicle routing problems," *COMPUTERS & OPERATIONS RESEARCH*, vol. 34, no. 8, pp. 2403-2435, 2007.
- [110] C. Prins, "A simple and effective evolutionary algorithm for the vehicle routing problem," *Computers & Operations Research*, vol. 31, pp. 1985–2002, 2004.
- [111] C. Prins and S. Bouchenoua, "A memetic algorithm solving the VRP the CARP and general routing problems with nodes edges and arcs," in *Recent advances in memetic algorithms studies in fuzziness and soft computing.*: Springer, 2004, pp. 65–85.
- [112] B. Przybysławski, "Sposoby wyznaczania odpornych tras komiwojażera w przedsiębiorstwie," *Journal of Management and Finance*, no. 1/2, 2013.
- [113] D. Pyza, "Wybrane aspekty modelowania obsługi transportowej w podsystemach dystrybucji," *Prace Naukowe Politechniki Warszawskiej*, no. z.70, pp. 139-149, 2009.
- [114] A.G. Qureshi, E. Taniguchi, and T. Yamada, "An exact solution approach for vehicle routing and scheduling problems with soft time windows," *Transportation Research Part E*, vol. 45, pp. 960–977, 2009.
- [115] S. Ropke and D. Pisinger, "An adaptive large neighborhood search heuristic for the pickup and delivery problem with time windows," *Transportation Science*, vol. 40, no. 4, pp. 455-472, 2006.

- [116] R.A. Russell and W.C. Chiang, "Scatter search for the vehicle routing problem with time windows," *EUROPEAN JOURNAL OF OPERATIONAL RESEARCH*, vol. 169, no. 2, 2005.
- [117] J. Schoemaker, J. Allen, M. Huschebeck, and J. Monigl. "BESTUFS II: Quantification of Urban Freight Transport Effects I", 2006.
- [118] Web of Science. Web of Science. [Online]. <https://webofknowledge.com/>
- [119] SCOPUS. SCOPUS. [Online]. <http://www.scopus.com>
- [120] J.S. Shang and C.K. Cuff, "Multicriteria pickup and delivery problem with transfer opportunity," *Computers & Industrial Engineering*, vol. 30, no. 4, pp. 631-645, 1996.
- [121] A. Shapiro, S. Dentcheva, and A. Ruszczyński, "Lectures on stochastic programming: modeling and theory.: SIAM-Society for Industrial and Applied Mathematics", 2009.
- [122] A. Shapiro and A. Philpott, "A Tutorial on Stochastic Programming," 2007.
- [123] P. Sitek, J. Wikarek, and K. Grzybowska, "A Multi-Agent Approach to the Multi-Echelon Capacitated Vehicle Routing Problem," *Communications in Computer and Information Science*, vol. 430, pp. 121-132, 2014.
- [124] M.M. Solomon, "Algorithms for the vehicle routing and scheduling problems with time window constraints," *Operatoin Research*, vol. 35, no. 2, pp. 254-265, 1987.
- [125] O. Solyali, J.F. Cordeau, and G. Laporte, "Robust Inventory Routing Under Demand Uncertainty," *Transportation Science*, vol. 46, no. 3, pp. 327 - 340, 2011.
- [126] A. L. Soyster, "Convex programming with set-inclusive constraints and applications to inexact linear programming," *Operation Research*, vol. 21, pp. 1154-1157, 1973.
- [127] A. Subramanian, E. Uchoa, and i L.S. Och, "New Lower Bounds for the Vehicle Routing Problem with Simultaneous Pickup and Delivery," *Experimental Algorithms, Lecture Notes in Computer Science*, no. 6049, pp. 276-287, 2010.
- [128] SUGAR project. [Online]. <http://www.sugarlogistics.eu/>
- [129] A. Sun, Z. Duan, and D. Yang, "Urban freight management with stochastic time-dependent travel times and application to large-scale transportation networks," *Discrete Dynamics in Nature and Society*, 2015.
- [130] I. Sungur, F. Ordonez, and M. Dessouky, "A robust optimization approach for the capacitated vehicle routing," *IIE Transactions*, vol. 40, pp. 509-23, 2008.
- [131] A. Szarata i inni, ""Badania zachowań komunikacyjnych mieszkańców Krakowskiego Obszaru Metropolitarnego" wraz z opracowaniem zunifikowanej metodyki badań i modelowania ruchu dla Krakowskiego Obszaru Metropolitarnego," Kraków, 2014.
- [132] J. Szoltysek, "Logistyczne aspekty zarządzania przepływami osób i ładunków w miastach". Katowice: AE w Katowicach, 2005.
- [133] M. Szymczak, "O istocie i funkcjach logistyki miejskiej," in *Współczesne kierunki rozwoju logistyki*. Warszawa: PWE, 2006.
- [134] M. Tagmouti, M. Gendreau, and J.Y. Potvin, "A dynamic capacitated arc routing problem with time-dependent service costs," *Transportation Research Part C*, vol. 19, no. 1, pp. 20-28, 2011.
- [135] ED Taillard, "A heuristic column generation method for the heterogeneous fleet VRP," *Rairo-Recherche Operationnelle-Operations Research*, vol. 33, no. 1, pp. 1-14, 1999.
- [136] N. Tajik, R. Tavakkoli-Moghaddam, B. Vahdani, and S. Meysam Mousavi, "A robust optimization approach for pollution routing problem with pickup and delivery under uncertainty," *Journal of Manufacturing Systems*, vol. 33, no. 2, pp. 277 - 286, 2014.
- [137] K. C. Tan, C.Y. Cheong, and C.K. Goh, "Solving multiobjective vehicle routing problem with stochastic demand via evolutionary computation," *European Journal Of Operational Research*, vol. 177, no. 2, pp. 813-839, 2007.
- [138] E. Taniguchi and H. Shimamoto, "Intelligent transportation system based dynamic vehicle scheduling with variable travel times," *Transportation Research Part C*, vol. 12, no. 3-4, pp. 235-250, 2004.

- [139] E. Taniguchi and R.G. Thompson, "Innovations in City Logistics". Nova Science Publishers, 2008.
- [140] E. Taniguchi, R.I G. Thompson, and T. Yamada, "Modelling the behaviour of stakeholders in City Logistics," in *Innovations in City Logistics*. New York: Nova Science Publishers, Inc., 2008.
- [141] E. Taniguchi, R. G. Thompson, T. Yamada, and R. van Duin, *City logistics - network modelling and intelligent transport systems*. Oxford: Elsevier, Pergamon, 2001.
- [142] K. C. Tan, T. H. Lee, Y. H. Chew, and L. H. Lee, "A hybrid multiobjective evolutionary algorithm for solving truck and trailer vehicle routing problems," *IEEE Congress on Evolutionary Computation 2003*, Canberra, Australia, 8-12 December, pp. 2134-2141, 2003.
- [143] C.D. Tarantilis, C.T. Kiranoudis, and V.S. Vassiliadis, "A threshold accepting metaheuristic for the heterogeneous fixed fleet vehicle routing problem," *European Journal Of Operational Research*, vol. 152, no. 1, pp. 148-158, 2004.
- [144] A. Thiele, "Robust stochastic programming with uncertain probabilities," *IMA J Management Math*, vol. 19, no. 3, pp. 289-321, 2008.
- [145] P. Toth and D. Vigo, "The Vehicle Routing Problem". Philadelphia: Monographs on Discrete Mathematics and Applications. SIAM, 2002.
- [146] P. Toth and A. Vigo, "Vehicle Routing: Problems, Methods and Applications". Philadelphia: Society for Industrial and Applied Mathematics, 2014.
- [147] N. Touati and V. Jost, "On green routing and scheduling problem," *ArXiv e-prints*, 2012.
- [148] Trailblazer Project. [Online]. <http://trailblazer.eu/>
- [149] B. Tundys, "Logistyka miejska. Koncepcje, systemy, rozwiązania". Warszawa: Difin, 2008.
- [150] B. Tundys, "Logistyka miejska. Teoria i praktyka". Warszawa: Difin, 2013.
- [151] United Nations. (2014) "World Urbanization Prospects, the 2014 revision". [Online]. <http://esa.un.org/>
- [152] P.M. Verderame, J.A. Elia, J. J. Floudas, and C. A. Floudas, "Planning and Scheduling under Uncertainty: A Review Across Multiple Sectors," *Ind. Eng. Chem. Res.*, vol. 49, no. 9, pp. 3993-4017, 2010.
- [153] J.G.S.N. Visser and N. Nemoto, "E-Commerce and the Consequences for Freight Transport," in *Innovations in Freight Transport*. Southampton: WIT Press, 2002.
- [154] P. Wesołek and M. Kubiak, "Multiobjective fuzzy approach to the vehicle routing problem with time windows," *Diagnostyka*, no. nr 2(38), pp. 21-24, 2006.
- [155] M. Woch, "Rozwiązanie problemu dostaw z oknami czasowymi za pomocą symulowanego wyżarzania," *Studia Informatica*, vol. 25, no. 2, pp. 67-80, 2004.
- [156] M. Woch and P. Łebkowski, "Zastosowanie algorytmu symulowanego wyżarzania do rozwiązania problemu dostaw z oknami czasowymi," *Logistyka*, no. nr 2, 2010.
- [157] J. Wojciechowski and K. Piękosz, "Grafy i sieci". Warszawa: PWN, 2013.
- [158] L.A. Zadeh, "Fuzzy sets," *Information and Control*, vol. 8, no. 3, pp. 338-353, 1965.

SPIS RYSUNKÓW

RYSUNEK 2.1 GŁÓWNI AKTORZY I RELACJE SYSTEMU LOGISTYCZNEGO MIASTA W ODNIESIENIU DO TRANSPORTU TOWARÓW.	23
RYSUNEK 2.2 RELACJA I CZYNNIKI WPŁYWU POMIĘDZY TRANSPORTEM TOWARÓW W MIEŚCIE A POZOSTAŁYMI UCZESTNIKAMI.	24
RYSUNEK 2.3 DEKLAROWANE MIEJSCE ROZŁADUNKU (PO LEWEJ) ORAZ CZĘSTOTLIWOŚĆ DOSTAW (PO PRAWEJ).	31
RYSUNEK 2.4 CZĘŚCIOWE WYNIKI ANKIETY PROGRAMU CIVITAS CARAVEL W 2007 ROKU, DOTYCZĄCE TRANSPORTU TOWARÓW W ODBIORZE PIESZYCH I MIESZKAŃCÓW CENTRUM KRAKOWA.	32
RYSUNEK 2.5 ZASADA DZIAŁANIA MIEJSKIEGO CENTRUM KONSOLIDACYJNEGO.	34
RYSUNEK 2.6 PRZYKŁAD PROBLEMU VRP W POSTACI GRAFU (PO LEWEJ) ORAZ JEGO ROZWIĄZANIE (PO PRAWEJ).	36
RYSUNEK 2.7 ZAGREGOWANY SCHEMAT ODMIAN ZAGADNIENŃ VRP WRAZ Z ICH PODZIAŁEM NA GŁÓWNE KLASY	37
RYSUNEK 2.8 KONCEPCJA INTELIGENTNYCH SYSTEMÓW LOGISTYCZNYCH ILS W KONTEKŚCIE ZAGADNIENŃ WYZNACZANIA TRAS POJAZDÓW.	43
RYSUNEK 3.1 POGLĄDOWY SCHEMAT IDEI POSZUKIWANIA ROZWIĄZANIA W OPTIMALIZACJI ODPORNOŚCIOWEJ.	54
RYSUNEK 4.1. SKOKOWA FUNKCJA CZASU PRZEJAZDU DLA ODCINKA (I,J) Z CZTEREMA INTERWAŁAMI CZASU $M_{ij}=4$	74
RYSUNEK 4.2 FUNKCJA KARY ORAZ CHARAKTERYSTYKA ELASTYCZNEGO OKNA CZASOWEGO DLA I-TEGO KLIENTA.	75
RYSUNEK 4.3. RZECZYWISTA SIEĆ DROGOWA Z ZAZNACZONYMI KLIENTAMI (Z LEWEJ) ORAZ JEJ REPREZENTACJA W POSTACI GRAFU PEŁNEGO (Z PRAWEJ).	83
RYSUNEK 4.4. KONCEPCJA INTEGRACJI PROBLEMU R-SPP ODPORNEGO NA WAHANIA PARAMETRÓW Z PROBLEMAMI KLASY VRP.	89
RYSUNEK 4.5. PRZEPLÝW DANYCH W KONCEPCJI INTEGRACJI PROBLEMU R-SPP Z NORMALIZOWANYM PROBLEMEM VRP-STW.	100
RYSUNEK 5.1 ANALIZOWANY OBSZAR MIASTA KRAKOWA (PO LEWEJ) ORAZ JEGO MODEL W PROGRAMIE AIMSUN (PO PRAWEJ).	103
RYSUNEK 5.2 GRAF ANALIZOWANEJ SIECI MIASTA KRAKOWA. LINIA CIĄGŁA - ODCINKI DWUKIERUNKOWE, LINIA PRZERYWANA - ODCINKI JEDNOKIERUNKOWE.	104
RYSUNEK 5.3 PRZYKŁADOWY MODEL SKRZYŻOWANIA ORAZ PROJEKT PLANU SYGNALIZACJI ŚWIETLNEJ (PO PRAWEJ) W PROGRAMIE AIMSUN.	105
RYSUNEK 5.4 LOKALIZACJA PĘTLI INDUKCYJNYCH, Z KTÓRYCH WYKORZYSTANO DANE DO SYMULACJI.	107
RYSUNEK 5.5 DOBOWE NATĘŻENIA POJAZDÓW NA POSZCZEGÓLNYCH WLOTACH SKRZYŻOWANIA ULIC SŁOWACKIEGO I ŁOBZOWSKA W KRAKOWIE DLA DNI ROBOCZYCH. WLOT D1 - AL. SŁOWACKIEGO PÓLNOĆ; WLOT D2 - UL. ŁOBZOWSKA WSCHÓD; WLOT D3 - AL. SŁOWACKIEGO POŁUDNIE; WLOT D4 - UL. ŁOBZOWSKA ZACHÓD.	107
RYSUNEK 5.6 ŚREDNIE DOBOWE NATĘŻENIA POJAZDÓW NA POSZCZEGÓLNYCH WLOTACH SKRZYŻOWANIA ULIC SŁOWACKIEGO I ŁOBZOWSKA W KRAKOWIE DLA DNI ROBOCZYCH. WLOT D1 - AL. SŁOWACKIEGO PÓLNOĆ; WLOT D2 - UL. ŁOBZOWSKA WSCHÓD; WLOT D3 - AL. SŁOWACKIEGO POŁUDNIE; WLOT D4 - UL. ŁOBZOWSKA ZACHÓD.	108
RYSUNEK 5.7 PORÓWNANIE WYNIKÓW KALIBRACJI MACIERZY O-D Z RZECZYWISTYMI POMIARAMI DLA WYBRANEJ GODZINY.	109
RYSUNEK 5.8 FUNKCJA GĘSTOŚCI CZASU REAKCJI KIEROWCY NA SYGNAŁ ZIELONY.	111
RYSUNEK 5.9 FUNKCJA GĘSTOŚCI WSPÓŁCZYNNIKA ZMIENNOŚCI UZYSKANYCH DANYCH.	120
RYSUNEK 5.10 WYKRES ŚREDNIEGO CZASU PRZEJAZDU WRAZ Z ODCHYLENIEM STANDARDOWYM W ZALEŻNOŚCI OD GODZINY DNIA.	121
RYSUNEK 5.11. ŚREDNI CZAS OPTIMALIZACJI MODELU RC_{SPP}^* W ZALEŻNOŚCI OD WIELKOŚCI SIECI.	123
Rozprawa doktorska, Politechnika Krakowska	185

RYSUNEK 5.12. ZALEŻNOŚĆ WARTOŚCI FUNKCJI CELU MODELU RC_{SPP}^* OD PARAMETRU I^{SP}	123
RYSUNEK 5.13. ZMIENNOŚĆ ZNORMALIZOWANYCH KRYTERIÓW CZĄSTKOWYCH MODELU RC_{SPP}^* W ZALEŻNOŚCI OD WAGI ω^{SP}	124
RYSUNEK 5.14. WYKRESY PUNKTOWE WARTOŚCI KRYTERIÓW CZĄSTKOWYCH W ZALEŻNOŚCI OD WARTOŚCI WAG KRYTERIÓW DLA MODELU (nVRP1).....	128
RYSUNEK 5.15. WYKRESY PUNKTOWE WARTOŚCI KRYTERIÓW CZĄSTKOWYCH W ZALEŻNOŚCI OD WARTOŚCI WAG KRYTERIÓW DLA MODELU (nVRP2).....	129
RYSUNEK 5.16 PRZYKŁADOWA LOKALIZACJA 80 KLIENTÓW (CZERWONE KWADRATY) W REPREZENTACJI GRAFOWEJ ANALIZOWANEJ SIECI DROGOWEJ.	131
RYSUNEK 5.17 ŚREDNI CZAS OPTIMALIZACJI W ZALEŻNOŚCI OD LICZBY KLIENTÓW I PRZYJĘTEGO MODELU VRP.	132
RYSUNEK 5.18 ŚREDNI CZAS OPTIMALIZACJI DLA MODELU (nVRP1) W ZALEŻNOŚCI OD STRUKTURY OKIEN CZASOWYCH U KLIENTÓW.	134
RYSUNEK 5.19 ŚREDNI CZAS OPTIMALIZACJI DLA MODELU (nVRP2) W ZALEŻNOŚCI OD STRUKTURY OKIEN CZASOWYCH U KLIENTÓW.	135
RYSUNEK 6.1 OGÓLNY SCHEMAT PORÓWNYWANIA JAKOŚCI WARIANTÓW DETERMINISTYCZNEGO, STOCHASTYCZNEGO Z ODPORNOŚCIOWYM.	142
RYSUNEK 6.2 ŚREDNIA RÓŻNICA POMIĘDZY CZASEM PRZEJAZDU WARIANTU DETERMINISTYCZNEGO A WARIANTU ODPORNEGO W ZALEŻNOŚCI OD LICZBY KLIENTÓW ORAZ STOPNIA REALIZACJI NIEPEWNOŚCI DANYCH.	145
RYSUNEK 6.3 ŚREDNIA RÓŻNICA POMIĘDZY CZASEM WCZESNEGO PRZYJAZDU WARIANTU DETERMINISTYCZNEGO A WARIANTU ODPORNEGO W ZALEŻNOŚCI OD LICZBY KLIENTÓW ORAZ STOPNIA REALIZACJI NIEPEWNOŚCI DANYCH.	147
RYSUNEK 6.4 ŚREDNIA RÓŻNICA POMIĘDZY LICZBĄ WCZESNYCH PRZYJAZDÓW WARIANTU DETERMINISTYCZNEGO A WARIANTU ODPORNEGO W ZALEŻNOŚCI OD LICZBY KLIENTÓW, WARTOŚCI PARAMETRU KONSERWATYZMU ORAZ STOPNIA REALIZACJI NIEPEWNOŚCI DANYCH.....	148
RYSUNEK 6.5 ŚREDNIA RÓŻNICA POMIĘDZY CZASEM OPÓŹNIENIA WARIANTU DETERMINISTYCZNEGO A WARIANTU ODPORNEGO W ZALEŻNOŚCI OD LICZBY KLIENTÓW ORAZ STOPNIA REALIZACJI NIEPEWNOŚCI DANYCH.	149
RYSUNEK 6.6 ŚREDNIA RÓŻNICA POMIĘDZY LICZBĄ OPÓŹNIEŃ WARIANTU DETERMINISTYCZNEGO A WARIANTU ODPORNEGO W ZALEŻNOŚCI OD LICZBY KLIENTÓW, WARTOŚCI PARAMETRU KONSERWATYZMU ORAZ STOPNIA REALIZACJI NIEPEWNOŚCI DANYCH.	150
RYSUNEK 6.7 ŚREDNIA RÓŻNICA POMIĘDZY CZASEM PRZEJAZDU W PODEJŚCIU DETERMINISTYCZNYM A CZASEM PRZEJAZDU W PODEJŚCIU ODPORNYM W ZALEŻNOŚCI OD MODELU VRP.	153
RYSUNEK 6.8 ŚREDNIA RÓŻNICA POMIĘDZY DYSTANSEM W PODEJŚCIU DETERMINISTYCZNYM A DYSTANSEM W PODEJŚCIU ODPORNYM W ZALEŻNOŚCI OD MODELU VRP.....	153
RYSUNEK 6.9 ŚREDNIA RÓŻNICA POMIĘDZY CZASEM WCZESNEGO PRZYJAZDU W PODEJŚCIU DETERMINISTYCZNYM A CZASEM WCZESNEGO PRZYJAZDU W PODEJŚCIU ODPORNYM W ZALEŻNOŚCI OD MODELU VRP.....	154
RYSUNEK 6.10 ŚREDNIA RÓŻNICA POMIĘDZY CZASEM OPÓŹNIENIA W PODEJŚCIU DETERMINISTYCZNYM A CZASEM OPÓŹNIENIA W PODEJŚCIU ODPORNYM W ZALEŻNOŚCI OD MODELU VRP.	154
RYSUNEK 6.11 ŚREDNIA RÓŻNICA POMIĘDZY LICZBĄ WCZESNYCH PRZYJAZDÓW W PODEJŚCIU DETERMINISTYCZNYM A LICZBĄ WCZESNYCH PRZYJAZDÓW W PODEJŚCIU ODPORNYM W ZALEŻNOŚCI OD MODELU VRP.....	154
RYSUNEK 6.12 ŚREDNIA RÓŻNICA POMIĘDZY LICZBĄ PÓŹNYCH PRZYJAZDÓW W PODEJŚCIU DETERMINISTYCZNYM A LICZBĄ PÓŹNYCH PRZYJAZDÓW W PODEJŚCIU ODPORNYM W ZALEŻNOŚCI OD MODELU VRP.	155
RYSUNEK 6.13 ŚREDNIA RÓŻNICA POMIĘDZY CZASEM PRZEJAZDU W PODEJŚCIU DETERMINISTYCZNYM A CZASEM PRZEJAZDU W PODEJŚCIU ODPORNYM W ZALEŻNOŚCI OD STRUKTURY OKIEN CZASOWYCH KLIENTÓW.	156
RYSUNEK 6.14 ŚREDNIA RÓŻNICA POMIĘDZY DYSTANSEM W PODEJŚCIU DETERMINISTYCZNYM A DYSTANSEM W PODEJŚCIU ODPORNYM W ZALEŻNOŚCI OD STRUKTURY OKIEN CZASOWYCH KLIENTÓW.....	156
RYSUNEK 6.15 ŚREDNIA RÓŻNICA POMIĘDZY CZASEM WCZESNEGO PRZYJAZDU W PODEJŚCIU DETERMINISTYCZNYM A CZASEM WCZESNEGO PRZYJAZDU W PODEJŚCIU ODPORNYM W ZALEŻNOŚCI OD STRUKTURY OKIEN CZASOWYCH KLIENTÓW.....	156
RYSUNEK 6.16 ŚREDNIA RÓŻNICA POMIĘDZY CZASEM OPÓŹNIENIA W PODEJŚCIU DETERMINISTYCZNYM A CZASEM OPÓŹNIENIA W PODEJŚCIU ODPORNYM W ZALEŻNOŚCI OD STRUKTURY OKIEN CZASOWYCH KLIENTÓW.	157

RYSUNEK 6.17 ŚREDNIA RÓŻNICA POMIĘDZY LICZBĄ WCZESNYCH PRZYJAZDÓW W PODEJŚCIU DETERMINISTYCZNYM A LICZBĄ WCZESNYCH PRZYJAZDÓW W PODEJŚCIU ODPORNYM W ZALEŻNOŚCI STRUKTURY OKIEN CZASOWYCH KLIENTÓW.....	157
RYSUNEK 6.18 ŚREDNIA RÓŻNICA POMIĘDZY LICZBĄ PÓŹNYCH PRZYJAZDÓW W PODEJŚCIU DETERMINISTYCZNYM A LICZBĄ PÓŹNYCH PRZYJAZDÓW W PODEJŚCIU ODPORNYM W ZALEŻNOŚCI STRUKTURY OKIEN CZASOWYCH KLIENTÓW.....	157
RYSUNEK 6.19 WPLYW ZMIANY STOPNIA ODCHYLENIA CZASU PRZEJAZDU I STOPNIA REALIZACJI DANYCH NA ZNORMALIZOWANĄ WARTOŚĆ FUNKCJI CELU W PODEJŚCIU DETERMINISTYCZNYM.....	159
RYSUNEK 6.20 WPLYW ZMIANY POZIOMU KONSERWATYZMU I STOPNIA REALIZACJI DANYCH NA ZNORMALIZOWANĄ WARTOŚĆ FUNKCJI CELU W PODEJŚCIU ODPORNYM.....	160
RYSUNEK 6.21 ŚREDNIA RÓŻNICA POMIĘDZY CZASEM PRZEJAZDU WARIANTU STOCHASTYCZNEGO A WARIANTU ODPORNEGO PRZY $\Gamma = 20$ W ZALEŻNOŚCI OD LICZBY KLIENTÓW ORAZ STOPNIA REALIZACJI NIEPEWNOŚCI DANYCH.....	162
RYSUNEK 6.22 ŚREDNIA RÓŻNICA POMIĘDZY CZASEM WCZESNYCH PRZYJAZDÓW WARIANTU STOCHASTYCZNEGO A WARIANTU ODPORNEGO PRZY $\Gamma = 20$ W ZALEŻNOŚCI OD LICZBY KLIENTÓW ORAZ STOPNIA REALIZACJI NIEPEWNOŚCI DANYCH.....	164
RYSUNEK 6.23 ŚREDNIA RÓŻNICA POMIĘDZY LICZBĄ WCZESNYCH PRZYJAZDÓW WARIANTU STOCHASTYCZNEGO A WARIANTU ODPORNEGO PRZY $\Gamma = 20$ W ZALEŻNOŚCI OD LICZBY KLIENTÓW ORAZ STOPNIA REALIZACJI NIEPEWNOŚCI DANYCH.....	165
RYSUNEK 6.24 ŚREDNIA RÓŻNICA POMIĘDZY CZASEM OPÓŹNIENIA WARIANTU STOCHASTYCZNEGO A WARIANTU ODPORNEGO PRZY $\Gamma = 20$ W ZALEŻNOŚCI OD LICZBY KLIENTÓW ORAZ STOPNIA REALIZACJI NIEPEWNOŚCI DANYCH.....	166
RYSUNEK 6.25 ŚREDNIA RÓŻNICA POMIĘDZY LICZBĄ OPÓŹNIEŃ WARIANTU STOCHASTYCZNEGO A WARIANTU ODPORNEGO PRZY $\Gamma = 20$ W ZALEŻNOŚCI OD LICZBY KLIENTÓW ORAZ STOPNIA REALIZACJI NIEPEWNOŚCI DANYCH.....	167
RYSUNEK 6.26 WPLYW ZMIANY PRAWDOPODOBIEŃSTWA WARTOŚCI CZASU PRZEJAZDU I STOPNIA REALIZACJI DANYCH NA ZNORMALIZOWANĄ WARTOŚĆ FUNKCJI CELU W PODEJŚCIU STOCHASTYCZNYM.....	170
RYSUNEK 6.27 WPLYW ZMIANY POZIOMU KONSERWATYZMU I STOPNIA REALIZACJI DANYCH NA ZNORMALIZOWANĄ WARTOŚĆ FUNKCJI CELU W PODEJŚCIU ODPORNYM.....	170

SPIS TABEL

TABELA 2-1 WYBRANE DEFINICJE LOGISTYKI MIEJSKIEJ.	22
TABELA 2-2 RÓŻNICE POMIĘDZY TRADYCYJNYMI DOSTAWAMI, A DOSTAWAMI HANDLU ELEKTRONICZNEGO.	26
TABELA 2-3 ŚREDNI CZAS OPÓŹNIEŃ SPOWODOWANYCH WYSTĘPOWANIEM KONGESTII W POLSKICH MIASTACH.	27
TABELA 2-4 OCZEKIWANIA UCZESTNIKÓW TOWAROWEGO SYSTEMU TRANSPORTOWEGO.	28
TABELA 2-5 ZADANIA WARSTW I NARZĘDZIA WSPOMAGAJĄCE W KONTEKŚCIE HIERARCHICZNEGO SYSTEMU ILS DLA PROBLEMATYKI WYZNACZANIA TRAS POJAZDÓW.	45
TABELA 3-1 CECHY CHARAKTERYSTYCZNE SYSTEMU TRANSPORTOWEGO MIASTA.	48
TABELA 3-2 CECHY PODEJŚĆ DO PROBLEMU WYZNACZANIA TRAS POJAZDOM Z NIEPEWNYMI WARTOŚCIAMI CZASÓW PRZEJAZDÓW W LITERATURZE PRZEDMIOTU.	67
TABELA 4-1. WARIANTY INTEGRACJI PROBLEMÓW SPP Z PROBLEMAMI VRP.	88
TABELA 5-1 PROCENTOWY UDZIAŁ KATEGORII POJAZDÓW W RUCHU DROGOWYM DLA CENTRUM MIASTA KRAKOWA.	106
TABELA 5-2 GODZINOWA LICZBA POJAZDÓW W WYBRANYCH PUNKTACH DLA CENTRUM KRAKOWA DLA GODZIN 6:00 - 21:00 W DNIU ROBOCZYM CZWARTEK 04.12.2014R. - POMIAR RZECZYWISTY.	114
TABELA 5-3 GODZINOWA LICZBA POJAZDÓW W WYBRANYCH PUNKTACH DLA CENTRUM KRAKOWA DLA GODZIN 6:00 - 21:00 W DNIU ROBOCZYM CZWARTEK 04.12.2014R. - WYNIKI SYMULACJI KOMPUTEROWYCH.	116
TABELA 5-4 WSKAŹNIKI GEH DLA SYMULACJI MIKROSKOPOWYCH DLA POSZCZEGÓLNYCH DETEKTORÓW I GODZIN.	118
TABELA 5-5. CZAS OBLICZEŃ W ZALEŻNOŚCI OD ROZMIARU SIECI ORAZ OD PARAMETRU KONTROLI POZIOMU KONSERWATYZMU.	122
TABELA 5-6. POZYTYWNE I NEGATYWNE ASPEKTY STOSOWANIA RC_{SPP}^* W ODNIESIENIU DO DETERMINISTYCZNEGO MODELU (SPP) DLA CZASU TRWANIA ORAZ DŁUGOŚCI ŚCIEŻKI.	126
TABELA 5-7. PORÓWNANIE WARTOŚCI WAG KRYTERIÓW W ROZWIĄZANIEM IDEALNYM.	130
TABELA 5-8 ŚREDNI CZAS OPTIMALIZACJI DLA MODELI ($nVRP1$) ORAZ ($nVRP2$) W ZALEŻNOŚCI OD LICZBY KLIENTÓW I ZAKŁADANEJ LICZBY TRAS.	133
TABELA 5-9 ŚREDNIA LICZBA TRAS K^* UZYSKANYCH PRZY ROZWIĄZANIU MODELU ($nVRP2$) DLA ANALIZOWANYCH PRZYKŁADÓW.	134
TABELA 6-1 RÓŻNICA POMIĘDZY DYSTANSEM WARIANTU DETERMINISTYCZNEGO A WARIANTU ODPORNEGO W ZALEŻNOŚCI OD LICZBY KLIENTÓW ORAZ WARTOŚCI PARAMETRU KONSERWATYZMU ORAZ PROCENTOWY WZROST/SPADEK.	146
TABELA 6-2 MINIMALNA, ŚREDNIA I MAKSYMALNA LICZBA TRAS W ROZWIĄZANIU ZAGADNIENIA VRP DLA PODEJŚCIA DETERMINISTYCZNEGO I ODPORNEGO.	151
TABELA 6-3 CZAS OPTIMALIZACJI ORAZ ŁĄCZNY CZAS OPTIMALIZACJI ZAGADNIENIA VRP Z ZALEŻNOŚCI OD LICZY KLIENTÓW I POZIOMU KONSERWATYZMU.	152
TABELA 6-4 RÓŻNICA POMIĘDZY DYSTANSEM WARIANTU STOCHASTYCZNEGO A WARIANTU ODPORNEGO W ZALEŻNOŚCI OD LICZBY KLIENTÓW ORAZ WARTOŚCI PARAMETRU KONSERWATYZMU ORAZ PROCENTOWY WZROST/SPADEK.	163
TABELA 6-5 MINIMALNA, ŚREDNIA I MAKSYMALNA LICZBA TRAS W ROZWIĄZANIU ZAGADNIENIA VRP DLA PODEJŚCIA STOCHASTYCZNEGO I ODPORNEGO.	168
TABELA 6-6 CZAS OPTIMALIZACJI ORAZ ŁĄCZNY CZAS OPTIMALIZACJI ZAGADNIENIA VRP Z ZALEŻNOŚCI OD LICZY KLIENTÓW I POZIOMU KONSERWATYZMU.	168
TABELA 7-1 SYNTETYCZNE PORÓWNANIE PODEJŚCIA ODPORNEGO NA WAHANIA PARAMETRÓW MODELU Z PODEJŚCIEM DETERMINISTYCZNYM ORAZ Z STOCHASTYCZNYM.	172

Załącznik A. MODEL WYZNACZANIA ZAKRESU ZMIENNOŚCI KRYTERIÓW CZĄSTKOWYCH

W załączniku zaprezentowano model matematyczny zagadnienia na podstawie, którego otrzymywano zakres potencjalnej zmienności kryterium cząstkowego czasu lub dystansu używanych w modelu ($nVRP1$). Model ten jest modyfikacją wspomnianego modelu z pominięciem wielokryterialności celu oraz ograniczeń wynikających z istnienia okien czasowych. W celu zachowania czytelności, poniżej przedstawiono zmienioną wersję modelu ($nVRP1$). Przyjmując oznaczenia i założenia danych modelu ($nVRP1$) problem można sformułować następująco.

Zmienne decyzyjne:

$x_{ij}^{VRP} \in \{0,1\}$ - zmienna binarna określająca, czy dany łuk (i,j) znajduje się w rozwiązaniu,

$df_{ij}^{VRP} \geq 0$ - zmienna określająca ilość towaru rozwożonego, znajdującego się w pojeździe przejeżdżającego przez łuk (i,j) - przepływ towarów w przód,

$sf_{ij}^{norm} \geq 0$ - zmienna określająca ilość towaru zbieranego, znajdującego się w pojeździe

Funkcja kryterialna dla określenia minimalnego zakresu zmienności funkcji:

$$(VRP_{min}^{norm}): \min_{(f_1^{VRP}, f_2^{VRP})} (\beta \cdot f_1^{VRP} + (1 - \beta) \cdot f_2^{VRP})$$

Funkcja kryterialna dla określenia maksymalnego zakresu zmienności funkcji:

$$(VRP_{max}^{norm}): \max_{(f_1^{VRP}, f_2^{VRP})} (\beta \cdot f_1^{VRP} + (1 - \beta) \cdot f_2^{VRP})$$

Gdzie:

$\beta \in \{0,1\}$ - oznacza, dla którego kryterium cząstkowego są wykonywane obliczenia. Jeśli $\beta = 1$, to optymalizacja będzie wykonywana dla kryterium czasu, a jeśli $\beta = 0$ optymalizacja będzie wykonywana dla kryterium dystansu.

Ograniczenia definiujące poprawność przepływu:

$$\sum_{i \in VP} x_{ij}^{VRP} = 1, \quad \forall j \in VP_K \setminus \{1\}$$

$$\sum_{j \in VP_k \setminus \{1\}} x_{ij}^{VRP} = 1, \quad \forall i \in VP_c$$

$$\sum_{j \in VP_c} x_{ij}^{VRP} = K$$

Ograniczenia pojemnościowe:

$$\sum_{j \in VP_k} df_{ji}^{VRP} - \sum_{j \in VP_k} df_{ij}^{VRP} = d_i, \quad \forall i \in VP_c$$

$$\sum_{j \in VP_k} sf_{ij}^{VRP} - \sum_{j \in VP_k} sf_{ji}^{VRP} = s_i, \quad \forall i \in VP_c$$

$$df_{ij}^{VRP} + sf_{ij}^{VRP} \leq Q \cdot x_{ij}^{VRP}, \quad \forall (i, j) \in AP_K^{VRP}$$

Natura zmiennych:

$$x_{ij}^{VRP} \in \{0,1\}, \quad \forall (i, j) \in AP_K^{VRP}$$

$$df_{ij}^{VRP} \in \mathbb{R}^+, \quad \forall (i, j) \in AP_K^{VRP}$$

$$sf_{ij}^{VRP} \in \mathbb{R}^+, \quad \forall (i, j) \in AP_K^{VRP}$$

Sens i znaczenie powyższych ograniczeń jest takie samo jak w modelu (*nVRP1*). Dobór funkcji kryterialnej zależy od celu: czy wyznaczana jest dolna, czy górna granica zmienności danej funkcji celu. Otrzymana w drodze obliczeń wartość funkcji celu jest dolnym, bądź górnym ograniczeniem wartości cząstkowej funkcji kryterialnej dla modelu (*nVRP1*). Parametr β zapewnia, że zadanie optymalizacyjne będzie miało tylko jedno kryterium.

Załącznik B. TABELE Z WYNIKAMI SYMULACJI

Zaprezentowane poniżej tabele zawierają rezultaty wykonanych symulacji, w których dokonano porównania zaproponowanego podejścia uwzględniania niepewności wartości danych z podejściem deterministycznym i stochastycznym. Porównania rozwiązań zagadnienia VRP dokonano zgodnie z opisem zaprezentowanym w rozdziale 7.

Każde rozwiązanie przykładu testowego zostało podane sprawdzeniu jakości przez wprowadzenie losowo wygenerowanych 50 scenariuszy ruchowych. Następnie zostały obliczone parametry oceniające. Dla każdego z 50 losowych scenariuszy dokonano porównania z jego odpowiednikiem (deterministycznym oraz stochastycznym) - obliczono różnicę wartości parametru oceniającego i/lub jego redukcję. Dla tak przygotowanego zestawu różnic wartości oraz wartości redukcji obliczoną średnią. Zatem każdy z przykładów testowych, został scharakteryzowany wartością średnią obliczoną na podstawie losowych scenariuszy.

Dane w tabelach poniżej prezentują minimalne, średnie oraz maksymalne wartości dla zagregowanych wartości średnich losowych scenariuszy. Agregacji dokonano poprzez wybór wspólnej cechy jaką jest: liczebność zbioru klientów, wariant scenariusza porównawczego oraz poziom konserwatywności lub prawdopodobieństwa, odpowiednio. I tak dla przykładu: wartość minimalna, średnia i maksymalna dla 20 klientów o zmienności scenariusza 20% i poziomie konserwatywności "Gamma 5" zostały obliczone na zbiorze przykładów testowych z oboma strukturami okien czasowych, zdefiniowanych oboma typami modeli oraz dla wszystkich liczebności pojazdów - łącznie 20 przykładów.

PORÓWNANIE Z WARIANTEM DETERMINISTYCZNYM

Czas przejazdu

Tabela B. 1 Minimalna, średnia oraz maksymalna wartość średniej różnicy czasu przejazdu pomiędzy rozwiązaniami w ujęciu deterministycznym, a rozwiązaniami w ujęciu odpornym na wahania parametrów modelu dla problemu VRP.

Liczba klientów	Zmienność	Średnia wartość różnicy w: Czas przejazdu [min]								
		Gamma 5			Gamma 20			Gamma maks.		
		Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum
20	Scenariusz 20%	-1,0	0,4	1,8	3,9	5,3	6,8	2,7	4,1	5,4
	Scenariusz 50%	0,4	2,4	4,6	5,8	7,8	9,8	4,4	6,6	8,5
	Scenariusz 80%	1,0	3,5	6,4	7,3	10,1	13,4	7,6	10,0	12,6
	Scenariusz 100%	2,4	5,1	7,8	9,7	12,5	15,4	10,1	12,6	15,3
	Scenariusz 120%	4,2	7,0	9,8	12,2	15,1	18,0	12,4	15,1	17,8
	Scenariusz 150%	2,7	8,0	12,9	11,5	16,3	21,1	12,4	17,1	21,6
25	Scenariusz 20%	3,7	5,1	6,6	1,2	2,5	3,9	1,0	2,2	3,5
	Scenariusz 50%	5,9	8,0	9,9	3,4	5,3	7,3	2,8	4,6	6,5
	Scenariusz 80%	8,2	11,1	13,9	5,5	8,3	11,3	5,5	8,2	10,9
	Scenariusz 100%	10,4	13,5	16,4	8,1	10,8	13,5	7,7	10,3	13,0
	Scenariusz 120%	12,2	15,1	17,9	10,8	13,4	16,2	10,0	12,5	15,5
	Scenariusz 150%	11,9	16,9	21,7	10,5	15,2	20,1	9,9	14,6	19,5

		Średnia wartość różnicy w: Czas przejazdu [min]								
Liczba klientów	Zmienność	Gamma 5			Gamma 20			Gamma maks.		
		Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum
30	Scenariusz 20%	-4,6	-3,7	-2,8	-1,6	-0,7	0,2	0,5	1,3	2,1
	Scenariusz 50%	-4,6	-3,2	-1,9	-0,7	0,7	2,2	2,0	3,3	4,6
	Scenariusz 80%	-4,8	-3,0	-1,3	-0,1	1,6	3,7	3,3	5,0	6,8
	Scenariusz 100%	-4,6	-2,6	-0,7	1,2	3,1	5,2	5,1	6,9	8,7
	Scenariusz 120%	-4,7	-2,9	-1,2	2,2	4,1	6,1	6,3	8,0	9,9
	Scenariusz 150%	-5,6	-2,6	0,6	2,2	5,4	8,7	5,9	9,1	12,1
35	Scenariusz 20%	4,2	5,3	6,4	2,3	3,5	4,6	-4,7	-3,6	-2,5
	Scenariusz 50%	5,7	7,4	8,9	3,9	5,9	7,6	-4,4	-2,8	-1,2
	Scenariusz 80%	7,9	10,0	12,1	6,0	8,4	10,6	-3,4	-1,3	0,9
	Scenariusz 100%	9,7	12,0	14,2	8,4	10,8	13,0	-2,8	-0,5	1,6
	Scenariusz 120%	12,1	14,3	16,5	10,5	13,1	15,3	-2,1	0,1	2,2
	Scenariusz 150%	11,7	15,7	19,8	10,4	14,9	18,7	-3,6	0,4	4,2
40	Scenariusz 20%	5,9	7,5	8,7	7,9	9,2	10,7	8,0	9,5	11,0
	Scenariusz 50%	7,4	9,7	12,0	9,1	11,4	14,0	10,6	12,9	15,2
	Scenariusz 80%	9,3	12,1	15,3	11,1	14,2	17,3	13,7	16,9	19,8
	Scenariusz 100%	12,2	15,2	18,1	12,3	15,8	18,9	16,5	19,7	22,5
	Scenariusz 120%	14,3	17,4	20,6	14,7	17,6	20,8	19,3	22,3	25,4
	Scenariusz 150%	13,1	18,2	23,6	13,7	18,9	24,1	19,5	24,6	29,9
45	Scenariusz 20%	1,6	3,2	4,7	2,5	4,1	5,8	-6,2	-4,5	-2,9
	Scenariusz 50%	2,4	4,6	6,9	4,0	6,2	8,6	-6,6	-4,0	-1,3
	Scenariusz 80%	2,7	5,8	9,0	5,4	8,2	11,2	-6,5	-3,1	0,3
	Scenariusz 100%	4,2	7,4	10,5	7,3	10,1	12,9	-6,1	-2,7	0,6
	Scenariusz 120%	6,4	9,4	12,3	8,6	11,7	14,6	-5,5	-2,0	1,6
	Scenariusz 150%	5,5	10,5	15,7	8,3	13,6	18,7	-6,9	-1,0	4,9
50	Scenariusz 20%	-3,8	-1,7	0,4	-1,4	0,8	2,9	8,1	10,0	12,2
	Scenariusz 50%	-2,9	-0,3	2,5	0,4	3,2	6,2	10,1	12,8	15,8
	Scenariusz 80%	-2,3	1,7	5,4	2,1	5,9	9,7	12,0	15,8	19,8
	Scenariusz 100%	-0,5	3,5	7,1	4,6	8,7	12,6	15,3	19,2	23,1
	Scenariusz 120%	0,7	4,7	8,4	5,5	9,9	13,9	18,8	22,7	26,8
	Scenariusz 150%	-2,2	5,0	11,5	4,9	11,8	18,4	18,4	25,4	32,6
55	Scenariusz 20%	7,7	9,4	10,9	0,9	2,5	3,9	-1,6	0,1	1,5
	Scenariusz 50%	10,7	13,0	15,1	3,9	6,1	8,5	0,2	2,7	4,9
	Scenariusz 80%	13,7	16,9	19,6	6,0	9,0	12,4	2,5	5,7	8,6
	Scenariusz 100%	16,9	20,1	23,2	8,9	12,1	15,3	4,8	7,9	10,9
	Scenariusz 120%	19,5	22,7	25,6	11,9	15,0	18,6	7,3	10,5	13,8
	Scenariusz 150%	20,0	25,2	30,8	11,6	17,1	23,2	6,9	12,1	18,1
60	Scenariusz 20%	-1,0	0,5	2,1	10,9	12,4	14,1	0,2	1,8	3,3
	Scenariusz 50%	0,2	2,3	4,9	16,3	18,6	20,7	2,3	4,8	7,2
	Scenariusz 80%	3,5	6,4	9,5	21,4	24,6	27,8	5,4	8,6	11,6
	Scenariusz 100%	6,3	9,1	12,5	25,8	28,9	31,9	7,0	10,4	13,7
	Scenariusz 120%	7,7	10,7	14,2	31,5	34,5	37,6	8,9	12,3	15,5
	Scenariusz 150%	6,8	12,3	18,2	33,2	38,8	45,1	7,3	13,4	19,1
65	Scenariusz 20%	-0,4	1,7	3,7	-5,1	-2,9	-0,9	3,0	5,2	7,3
	Scenariusz 50%	3,3	6,3	9,3	-3,5	-0,1	3,3	6,4	9,9	13,0
	Scenariusz 80%	5,9	10,1	13,8	-2,0	2,4	6,4	9,5	14,1	18,0
	Scenariusz 100%	8,2	12,0	15,6	-1,4	2,6	6,4	12,6	17,1	20,7
	Scenariusz 120%	10,8	15,0	18,9	-0,1	4,2	8,3	16,8	21,2	25,0
	Scenariusz 150%	10,3	17,6	24,6	-0,4	6,3	13,5	16,9	25,0	31,7
70	Scenariusz 20%	8,4	9,9	11,5	-5,1	-3,6	-2,1	-12,3	-10,5	-8,8

		Średnia wartość różnicy w: Czas przejazdu [min]								
Liczba klientów	Zmienność	Gamma 5			Gamma 20			Gamma maks.		
		Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum
	Scenariusz 50%	12,5	14,8	17,3	-3,2	-0,9	1,6	-12,0	-9,6	-7,0
	Scenariusz 80%	17,2	20,6	24,0	-1,4	2,0	6,2	-11,6	-8,1	-4,6
	Scenariusz 100%	22,3	25,3	28,5	1,4	4,8	8,5	-8,9	-5,7	-2,2
	Scenariusz 120%	26,1	29,1	32,2	3,4	6,8	10,1	-8,4	-5,1	-1,8
	Scenariusz 150%	26,9	32,2	37,7	3,0	8,9	14,5	-10,9	-4,5	1,9
75	Scenariusz 20%	3,0	5,5	7,7	-6,8	-4,1	-1,5	-	-	-
	Scenariusz 50%	5,8	9,0	12,4	-5,8	-2,2	1,4	-	-	-
	Scenariusz 80%	7,1	11,8	16,9	-4,9	-0,1	4,5	-	-	-
	Scenariusz 100%	9,1	13,9	18,7	-3,1	1,8	6,5	-	-	-
	Scenariusz 120%	10,4	15,2	19,3	-2,3	2,3	6,7	-	-	-
	Scenariusz 150%	8,2	16,2	23,9	-4,8	3,4	11,0	-	-	-
80	Scenariusz 20%	0,3	2,6	5,1	12,0	14,2	16,1	-3,5	-1,5	0,8
	Scenariusz 50%	0,3	3,8	6,8	14,1	17,0	20,3	-4,1	-1,1	2,0
	Scenariusz 80%	1,3	5,4	9,7	15,1	19,3	23,4	-4,6	-0,4	4,0
	Scenariusz 100%	1,5	6,5	10,7	17,1	21,7	25,7	-3,3	1,1	5,8
	Scenariusz 120%	3,3	7,3	11,5	20,6	24,4	29,0	-0,8	3,6	8,3
	Scenariusz 150%	2,4	9,4	17,0	20,9	28,0	35,8	-0,8	6,1	14,3

Źródło: opracowanie własne.

Tabela B. 2 Minimalna, średnia oraz maksymalna wartość średniej redukcji czasu przejazdu pomiędzy rozwiązaniami w ujęciu deterministycznym, a rozwiązaniami w ujęciu odpornym na wahania parametrów modelu dla problemu VRP.

Liczba klientów	Zmienność	Średnia redukcja w: Czas przejazdu [%]								
		Gamma 5			Gamma 20			Gamma maks.		
		Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum
20	Scenariusz 20%	-2,1%	-0,3%	1,3%	4,2%	5,8%	7,5%	2,9%	4,5%	5,9%
	Scenariusz 50%	-0,4%	1,6%	3,7%	5,3%	7,2%	9,0%	4,0%	6,0%	7,7%
	Scenariusz 80%	0,1%	2,3%	4,6%	5,7%	8,0%	10,6%	6,0%	7,8%	9,7%
	Scenariusz 100%	1,2%	3,2%	5,2%	6,9%	8,9%	11,0%	7,1%	8,8%	10,5%
	Scenariusz 120%	2,2%	4,0%	5,9%	7,9%	9,7%	11,5%	7,9%	9,5%	11,1%
	Scenariusz 150%	1,1%	4,3%	7,3%	7,0%	9,8%	12,6%	7,4%	10,0%	12,5%
25	Scenariusz 20%	2,6%	4,0%	5,4%	-0,1%	1,2%	2,6%	0,1%	1,3%	2,6%
	Scenariusz 50%	3,8%	5,5%	7,1%	1,6%	3,2%	4,8%	1,5%	3,0%	4,6%
	Scenariusz 80%	4,8%	6,8%	8,7%	2,7%	4,7%	6,8%	3,3%	5,1%	6,9%
	Scenariusz 100%	5,6%	7,5%	9,3%	4,0%	5,7%	7,5%	4,2%	5,9%	7,5%
	Scenariusz 120%	6,1%	7,7%	9,2%	5,2%	6,7%	8,3%	5,2%	6,6%	8,2%
	Scenariusz 150%	5,4%	8,1%	10,5%	4,7%	7,3%	9,8%	4,8%	7,3%	9,8%
30	Scenariusz 20%	-7,3%	-6,0%	-4,8%	-4,1%	-3,0%	-1,8%	-0,7%	0,4%	1,5%
	Scenariusz 50%	-6,1%	-4,6%	-3,2%	-2,8%	-1,3%	0,3%	1,0%	2,4%	3,9%
	Scenariusz 80%	-5,7%	-3,9%	-2,3%	-2,1%	-0,5%	1,3%	2,1%	3,7%	5,3%
	Scenariusz 100%	-5,0%	-3,2%	-1,6%	-0,9%	0,7%	2,3%	3,4%	4,9%	6,4%
	Scenariusz 120%	-4,7%	-3,3%	-1,9%	-0,3%	1,1%	2,6%	4,0%	5,3%	6,7%
	Scenariusz 150%	-5,2%	-2,9%	-0,5%	-0,3%	1,8%	4,1%	3,5%	5,7%	7,8%
35	Scenariusz 20%	2,5%	3,5%	4,6%	1,2%	2,4%	3,5%	-7,0%	-5,7%	-4,6%
	Scenariusz 50%	3,2%	4,6%	5,9%	2,2%	3,9%	5,2%	-6,0%	-4,6%	-3,1%
	Scenariusz 80%	4,1%	5,6%	7,1%	3,3%	5,0%	6,4%	-4,8%	-3,1%	-1,5%
	Scenariusz 100%	4,8%	6,2%	7,6%	4,4%	5,8%	7,2%	-4,2%	-2,5%	-1,1%
	Scenariusz 120%	5,6%	6,9%	8,2%	5,2%	6,6%	7,8%	-3,6%	-2,1%	-0,8%
	Scenariusz 150%	5,0%	7,1%	9,4%	4,8%	7,2%	9,2%	-4,4%	-2,0%	0,1%
40	Scenariusz 20%	3,7%	4,8%	5,7%	4,5%	5,5%	6,5%	4,1%	5,2%	6,2%
	Scenariusz 50%	4,1%	5,4%	6,8%	4,5%	6,0%	7,5%	4,9%	6,3%	7,7%
	Scenariusz 80%	4,4%	5,9%	7,5%	4,9%	6,5%	8,2%	5,7%	7,4%	8,9%
	Scenariusz 100%	5,3%	6,7%	8,0%	4,9%	6,5%	8,0%	6,4%	7,9%	9,2%
	Scenariusz 120%	5,6%	7,0%	8,4%	5,4%	6,7%	8,0%	6,8%	8,1%	9,4%
	Scenariusz 150%	4,8%	6,9%	9,1%	4,5%	6,8%	8,9%	6,4%	8,5%	10,6%
45	Scenariusz 20%	0,8%	1,9%	3,0%	1,2%	2,3%	3,5%	-6,3%	-5,0%	-3,8%
	Scenariusz 50%	1,1%	2,4%	3,8%	1,8%	3,1%	4,5%	-5,7%	-4,2%	-2,5%
	Scenariusz 80%	1,0%	2,6%	4,1%	2,1%	3,5%	5,0%	-5,3%	-3,4%	-1,6%
	Scenariusz 100%	1,6%	3,0%	4,4%	2,7%	3,9%	5,2%	-4,7%	-3,1%	-1,5%
	Scenariusz 120%	2,3%	3,5%	4,7%	2,9%	4,2%	5,3%	-4,1%	-2,6%	-1,1%
	Scenariusz 150%	1,7%	3,6%	5,6%	2,5%	4,6%	6,5%	-4,6%	-2,2%	0,1%
50	Scenariusz 20%	-4,2%	-2,9%	-1,6%	-3,1%	-1,8%	-0,6%	3,4%	4,5%	5,7%
	Scenariusz 50%	-3,1%	-1,8%	-0,4%	-1,8%	-0,4%	1,0%	3,8%	5,1%	6,4%
	Scenariusz 80%	-2,5%	-0,7%	0,9%	-0,8%	0,8%	2,3%	4,0%	5,5%	7,1%
	Scenariusz 100%	-1,6%	-0,1%	1,3%	0,2%	1,7%	3,1%	4,8%	6,1%	7,5%
	Scenariusz 120%	-1,1%	0,3%	1,5%	0,4%	1,9%	3,2%	5,4%	6,7%	8,0%
	Scenariusz 150%	-2,2%	0,3%	2,4%	0,2%	2,3%	4,3%	4,9%	7,0%	9,2%
55	Scenariusz 20%	4,0%	5,0%	5,9%	-0,4%	0,6%	1,5%	-1,4%	-0,4%	0,5%
	Scenariusz 50%	4,8%	5,9%	7,0%	1,1%	2,2%	3,5%	-0,3%	1,1%	2,2%
	Scenariusz 80%	5,4%	6,8%	7,9%	1,8%	3,1%	4,6%	0,8%	2,3%	3,6%
	Scenariusz 100%	6,1%	7,3%	8,5%	2,7%	3,9%	5,2%	1,7%	2,9%	4,2%

Liczba klientów	Zmienność	Średnia redukcja w: Czas przejazdu [%]								
		Gamma 5			Gamma 20			Gamma maks.		
		Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum
	Scenariusz 120%	6,4%	7,6%	8,6%	3,5%	4,6%	5,9%	2,5%	3,6%	4,8%
	Scenariusz 150%	6,2%	7,9%	9,8%	3,1%	5,0%	7,0%	2,1%	3,9%	6,0%
60	Scenariusz 20%	-1,3%	-0,3%	0,6%	6,2%	7,1%	8,0%	-0,2%	0,8%	1,6%
	Scenariusz 50%	-0,6%	0,5%	1,8%	7,8%	9,0%	9,9%	0,9%	2,1%	3,3%
	Scenariusz 80%	0,9%	2,2%	3,5%	8,9%	10,2%	11,5%	2,1%	3,4%	4,6%
	Scenariusz 100%	1,9%	3,0%	4,3%	9,7%	10,9%	11,9%	2,4%	3,7%	4,9%
	Scenariusz 120%	2,2%	3,2%	4,5%	10,8%	11,8%	12,8%	2,9%	4,0%	5,1%
	Scenariusz 150%	1,7%	3,5%	5,4%	10,7%	12,4%	14,3%	2,2%	4,1%	5,9%
65	Scenariusz 20%	-0,5%	0,5%	1,6%	-3,2%	-2,0%	-1,0%	0,7%	1,8%	2,9%
	Scenariusz 50%	1,1%	2,4%	3,6%	-2,1%	-0,7%	0,8%	1,8%	3,3%	4,5%
	Scenariusz 80%	1,8%	3,3%	4,6%	-1,4%	0,2%	1,6%	2,5%	4,1%	5,5%
	Scenariusz 100%	2,3%	3,5%	4,7%	-1,1%	0,1%	1,4%	3,2%	4,5%	5,7%
	Scenariusz 120%	2,8%	4,0%	5,2%	-0,8%	0,5%	1,7%	4,0%	5,2%	6,3%
	Scenariusz 150%	2,4%	4,4%	6,3%	-0,9%	1,0%	3,0%	3,7%	5,7%	7,5%
70	Scenariusz 20%	4,0%	4,8%	5,7%	-3,0%	-2,2%	-1,4%	-7,1%	-6,0%	-5,0%
	Scenariusz 50%	5,2%	6,2%	7,3%	-1,8%	-0,7%	0,4%	-5,9%	-4,7%	-3,5%
	Scenariusz 80%	6,3%	7,6%	8,9%	-0,9%	0,5%	2,1%	-4,9%	-3,5%	-2,1%
	Scenariusz 100%	7,4%	8,4%	9,5%	0,1%	1,3%	2,6%	-3,5%	-2,3%	-1,1%
	Scenariusz 120%	7,9%	8,9%	9,9%	0,7%	1,8%	2,8%	-3,1%	-2,0%	-0,9%
	Scenariusz 150%	7,7%	9,3%	10,8%	0,5%	2,3%	3,9%	-3,7%	-1,7%	0,3%
75	Scenariusz 20%	0,5%	1,6%	2,5%	-4,2%	-3,1%	-2,0%	-	-	-
	Scenariusz 50%	1,5%	2,6%	3,8%	-3,2%	-2,0%	-0,7%	-	-	-
	Scenariusz 80%	1,6%	3,0%	4,5%	-2,6%	-1,2%	0,2%	-	-	-
	Scenariusz 100%	1,9%	3,2%	4,5%	-2,0%	-0,7%	0,6%	-	-	-
	Scenariusz 120%	2,0%	3,2%	4,2%	-1,7%	-0,5%	0,5%	-	-	-
	Scenariusz 150%	1,4%	3,2%	5,0%	-2,2%	-0,3%	1,4%	-	-	-
80	Scenariusz 20%	-1,0%	0,0%	1,1%	3,8%	4,7%	5,6%	-3,3%	-2,4%	-1,3%
	Scenariusz 50%	-0,9%	0,4%	1,4%	3,8%	4,9%	6,1%	-3,1%	-1,9%	-0,8%
	Scenariusz 80%	-0,6%	0,7%	2,0%	3,5%	4,8%	6,1%	-3,0%	-1,6%	-0,2%
	Scenariusz 100%	-0,6%	0,8%	2,0%	3,5%	4,9%	6,0%	-2,4%	-1,1%	0,3%
	Scenariusz 120%	-0,1%	0,9%	2,0%	4,1%	5,1%	6,2%	-1,6%	-0,5%	0,7%
	Scenariusz 150%	-0,4%	1,2%	3,0%	3,8%	5,5%	7,3%	-1,7%	0,0%	2,0%

Źródło: opracowanie własne.

Czas wczesnego przyjazdu

Tabela B. 3 Minimalna, średnia oraz maksymalna wartość średniej różnicy czasu wczesnego przejazdu pomiędzy rozwiązaniami w ujęciu deterministycznym, a rozwiązaniami w ujęciu odpornym na wahania parametrów modelu dla problemu VRP.

Liczba klientów	Zmienność	Średnia wartość różnicy w: Czas wczesnego przyjazdu [min]								
		Gamma 5			Gamma 20			Gamma maks.		
		Mini-mum	Średnia	Maksi-mum	Mini-mum	Średnia	Maksi-mum	Mini-mum	Średnia	Maksi-mum
20	Scenariusz 20%	-138,2	-44,3	0,9	-143,3	-56,9	-14,3	-124,7	-50,7	-13,0
	Scenariusz 50%	-77,9	-25,2	-2,5	-92,8	-36,7	-11,0	-74,7	-31,0	-8,2
	Scenariusz 80%	-40,3	-11,2	0,1	-46,3	-20,8	-4,0	-40,9	-16,1	-3,8
	Scenariusz 100%	-23,8	-4,6	3,2	-26,4	-11,2	-1,6	-21,7	-7,3	1,8
	Scenariusz 120%	-17,3	-2,5	3,3	-20,9	-4,6	0,0	-11,7	-2,3	5,5
	Scenariusz 150%	-13,1	-1,4	3,2	-20,2	-2,9	0,0	-11,0	-1,3	5,5
25	Scenariusz 20%	-77,5	-42,0	-4,4	-140,5	-44,5	-12,9	-124,9	-48,9	-15,7
	Scenariusz 50%	-44,4	-25,1	2,4	-89,8	-28,4	-4,0	-77,3	-32,3	-1,3
	Scenariusz 80%	-24,2	-12,4	5,9	-48,7	-16,2	0,8	-38,6	-19,2	2,2
	Scenariusz 100%	-20,5	-6,3	5,9	-30,8	-8,9	4,6	-30,6	-12,0	6,0
	Scenariusz 120%	-19,5	-4,0	5,2	-24,8	-5,0	5,0	-26,2	-6,9	6,5
	Scenariusz 150%	-18,7	-3,4	4,5	-23,3	-3,8	1,9	-23,3	-5,2	3,4
30	Scenariusz 20%	-66,7	-33,7	-0,8	-79,9	-39,7	-11,3	-17,2	0,7	12,2
	Scenariusz 50%	-47,5	-21,3	4,7	-49,3	-25,1	-1,3	-10,6	0,5	18,0
	Scenariusz 80%	-33,7	-12,2	10,1	-31,3	-15,1	5,6	-14,4	0,2	17,7
	Scenariusz 100%	-25,9	-7,0	14,4	-21,4	-8,4	7,8	-16,2	-0,2	16,8
	Scenariusz 120%	-23,2	-4,5	15,5	-19,8	-4,0	9,7	-16,8	-0,4	16,0
	Scenariusz 150%	-22,9	-3,7	15,4	-19,7	-2,4	9,7	-17,1	-0,4	15,3
35	Scenariusz 20%	-116,8	-48,7	-11,2	-130,7	-71,6	-19,3	-132,1	-64,3	11,8
	Scenariusz 50%	-74,6	-30,7	-5,9	-93,7	-48,3	-12,9	-84,6	-43,5	7,3
	Scenariusz 80%	-42,2	-16,3	5,7	-60,4	-29,7	-5,5	-45,5	-27,0	0,7
	Scenariusz 100%	-34,1	-9,2	6,0	-42,6	-19,9	-2,6	-32,1	-16,1	-0,8
	Scenariusz 120%	-26,1	-5,3	4,1	-30,3	-12,7	-0,1	-30,0	-8,3	2,6
	Scenariusz 150%	-21,8	-3,6	2,6	-25,4	-9,6	0,0	-29,8	-5,2	3,4
40	Scenariusz 20%	-112,7	-62,2	-10,1	-141,0	-80,7	-23,7	-181,5	-74,6	-2,0
	Scenariusz 50%	-76,7	-34,6	-4,8	-100,7	-48,0	-7,0	-107,1	-48,5	2,2
	Scenariusz 80%	-49,7	-16,3	11,1	-70,5	-27,5	8,3	-64,5	-28,0	3,6
	Scenariusz 100%	-32,9	-7,8	19,0	-50,0	-16,1	16,0	-41,2	-16,9	4,3
	Scenariusz 120%	-19,8	-3,3	20,5	-31,4	-9,6	20,9	-27,7	-8,7	5,4
	Scenariusz 150%	-13,5	-1,7	20,5	-29,3	-7,7	19,7	-25,0	-5,8	6,8
45	Scenariusz 20%	-194,6	-95,4	-21,0	-228,6	-115,5	-11,5	-199,5	-120,9	-51,2
	Scenariusz 50%	-122,0	-58,2	-1,1	-150,6	-75,9	-2,2	-135,9	-84,6	-45,8
	Scenariusz 80%	-60,1	-32,0	8,9	-102,7	-44,3	10,1	-82,3	-54,0	-23,8
	Scenariusz 100%	-47,6	-18,2	10,0	-72,2	-24,2	13,7	-55,2	-35,3	-10,9
	Scenariusz 120%	-40,1	-11,4	10,5	-47,1	-10,5	16,1	-41,6	-21,9	-2,1
	Scenariusz 150%	-37,2	-8,7	10,3	-33,6	-7,3	15,0	-36,8	-16,9	0,0
50	Scenariusz 20%	-260,6	-149,5	-33,7	-352,4	-174,8	-61,3	-346,2	-181,4	-70,3
	Scenariusz 50%	-128,5	-77,1	-23,1	-211,2	-107,3	-44,7	-210,5	-107,1	-45,6
	Scenariusz 80%	-63,8	-30,5	-3,0	-114,0	-55,6	-20,6	-107,8	-54,1	-20,0
	Scenariusz 100%	-41,2	-13,2	5,4	-53,6	-29,7	-9,9	-52,2	-26,2	-7,7
	Scenariusz 120%	-27,1	-7,0	6,6	-38,4	-13,7	-0,6	-24,2	-9,3	6,1
	Scenariusz 150%	-22,1	-5,6	5,9	-36,5	-8,6	3,3	-21,5	-4,9	7,3
55	Scenariusz 20%	-191,8	-101,6	-28,3	-240,4	-136,5	-63,8	-281,2	-137,4	-21,2
	Scenariusz 50%	-114,1	-61,7	-24,5	-149,0	-89,1	-45,9	-173,1	-86,1	-18,3

Liczba klientów	Zmienność	Średnia wartość różnicy w: Czas wczesnego przyjazdu [min]								
		Gamma 5			Gamma 20			Gamma maks.		
		Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum
	Scenariusz 80%	-59,2	-32,8	-12,0	-86,6	-52,6	-29,6	-86,0	-47,9	-10,7
	Scenariusz 100%	-31,8	-17,7	-2,1	-61,1	-31,6	-10,8	-49,2	-26,3	6,6
	Scenariusz 120%	-27,4	-11,9	-0,1	-44,8	-17,9	0,0	-33,7	-12,3	21,3
	Scenariusz 150%	-25,7	-9,6	3,0	-34,0	-13,4	0,0	-30,8	-8,1	25,1
60	Scenariusz 20%	-186,2	-93,8	-57,5	-209,8	-125,1	-40,9	-222,2	-130,1	-51,8
	Scenariusz 50%	-122,4	-57,2	-35,4	-145,5	-78,9	-29,4	-144,4	-81,0	-20,7
	Scenariusz 80%	-73,6	-31,4	-4,6	-87,8	-41,9	3,1	-86,4	-45,3	-8,6
	Scenariusz 100%	-56,1	-15,7	11,5	-57,4	-22,6	11,5	-59,7	-26,3	-2,8
	Scenariusz 120%	-50,3	-8,7	14,8	-40,8	-11,5	22,8	-38,8	-14,1	4,0
	Scenariusz 150%	-47,0	-6,2	18,0	-36,1	-8,0	24,8	-28,6	-10,6	9,7
65	Scenariusz 20%	-271,6	-142,8	-57,6	-251,2	-166,8	-33,5	-689,1	-275,9	-135,6
	Scenariusz 50%	-145,8	-80,0	-20,7	-157,3	-96,0	3,3	-625,3	-208,3	-87,5
	Scenariusz 80%	-65,9	-36,2	6,2	-84,3	-45,7	24,4	-589,9	-153,3	-49,8
	Scenariusz 100%	-37,1	-18,4	9,8	-43,5	-21,6	28,8	-572,3	-122,9	-22,5
	Scenariusz 120%	-31,0	-11,3	3,7	-23,1	-7,4	28,8	-559,9	-101,8	-1,1
	Scenariusz 150%	-27,0	-8,5	0,3	-15,9	-3,9	28,8	-551,2	-93,2	4,4
70	Scenariusz 20%	-25,2	-2,2	25,2	-204,8	-115,2	-32,6	-296,1	-165,7	-70,7
	Scenariusz 50%	-25,6	-4,2	19,3	-133,2	-70,2	-17,1	-201,4	-113,9	-51,3
	Scenariusz 80%	-23,6	-4,5	11,9	-76,8	-38,0	-5,0	-173,3	-73,7	-25,5
	Scenariusz 100%	-19,5	-4,5	7,5	-46,6	-20,7	3,2	-156,8	-52,8	-8,0
	Scenariusz 120%	-16,4	-4,3	6,1	-26,0	-7,8	6,9	-142,1	-39,2	-2,8
	Scenariusz 150%	-15,5	-4,0	5,0	-21,1	-4,6	5,0	-131,9	-33,1	-0,7
75	Scenariusz 20%	-266,2	-157,0	-70,5	-315,8	-211,3	-139,9	-	-	-
	Scenariusz 50%	-155,2	-87,7	-20,1	-193,7	-137,0	-83,5	-	-	-
	Scenariusz 80%	-82,6	-42,7	4,1	-129,2	-78,4	-27,0	-	-	-
	Scenariusz 100%	-39,5	-21,2	6,4	-80,7	-47,9	-6,0	-	-	-
	Scenariusz 120%	-26,7	-11,7	10,6	-44,9	-28,2	-0,1	-	-	-
	Scenariusz 150%	-20,2	-7,0	10,9	-32,8	-21,0	0,0	-	-	-
80	Scenariusz 20%	-380,5	-211,2	-44,0	-458,7	-241,9	-119,7	-584,0	-361,1	-194,9
	Scenariusz 50%	-235,4	-124,5	-34,4	-263,8	-151,7	-76,5	-496,7	-272,5	-113,3
	Scenariusz 80%	-149,2	-63,3	-25,8	-148,0	-84,5	-39,9	-414,2	-204,2	-67,0
	Scenariusz 100%	-84,7	-30,7	2,8	-101,5	-47,7	-9,3	-368,0	-166,1	-32,6
	Scenariusz 120%	-51,6	-14,8	19,8	-76,2	-27,3	-0,8	-340,4	-141,3	-10,1
	Scenariusz 150%	-35,1	-9,5	23,3	-67,5	-20,5	0,7	-330,8	-131,1	0,1

Źródło: opracowanie własne.

Czas opóźnienia

Tabela B. 4 Minimalna, średnia oraz maksymalna wartość średniej różnicy czasu opóźnienia pomiędzy rozwiązaniami w ujęciu deterministycznym, a rozwiązaniami w ujęciu odpornym na wahania parametrów modelu dla problemu VRP.

Liczba klientów	Zmienność	Średnia wartość różnicy w: Czas opóźnienia [min]								
		Gamma 5			Gamma 20			Gamma maks.		
		Mini-mum	Średnia	Maksi-mum	Mini-mum	Średnia	Maksi-mum	Mini-mum	Średnia	Maksi-mum
20	Scenariusz 20%	-9,6	7,2	23,0	-5,9	8,9	25,6	-9,6	5,8	23,0
	Scenariusz 50%	-6,7	13,1	42,5	-7,4	16,3	42,5	-14,7	11,9	42,5
	Scenariusz 80%	-2,7	22,7	76,0	-8,9	28,1	77,3	-19,9	23,9	77,3
	Scenariusz 100%	-5,3	31,7	113,8	-11,5	40,4	121,4	-23,8	34,5	116,4
	Scenariusz 120%	-11,1	37,9	161,1	-11,2	53,6	191,6	-28,0	45,7	176,9
	Scenariusz 150%	-33,4	40,9	190,9	-13,8	62,5	244,6	-31,0	54,1	219,7
25	Scenariusz 20%	-5,1	10,8	31,1	-2,4	9,9	29,9	-7,4	8,4	29,9
	Scenariusz 50%	-7,2	22,5	64,6	-3,3	21,5	72,3	-8,3	19,6	72,3
	Scenariusz 80%	-9,3	37,1	129,2	-4,1	36,7	140,7	-8,7	35,7	140,7
	Scenariusz 100%	-11,0	51,0	183,9	0,5	52,5	201,2	-9,0	50,9	202,1
	Scenariusz 120%	-20,6	63,4	257,2	5,1	69,3	277,8	-10,2	67,8	274,1
	Scenariusz 150%	-27,8	72,7	300,2	8,0	82,8	326,3	-12,5	80,2	321,0
30	Scenariusz 20%	-24,8	5,8	29,0	-2,4	8,3	29,0	-13,7	4,0	29,7
	Scenariusz 50%	-25,2	11,6	47,8	-7,2	15,5	47,8	-32,1	5,6	41,0
	Scenariusz 80%	-25,2	18,5	69,4	-15,5	26,0	70,8	-58,5	8,3	58,9
	Scenariusz 100%	-22,7	25,5	89,7	-22,1	36,6	101,3	-87,6	10,3	72,7
	Scenariusz 120%	-17,9	31,5	118,9	-28,7	47,3	135,8	-117,2	11,2	87,3
	Scenariusz 150%	-18,5	36,1	143,3	-33,3	54,6	157,6	-147,4	11,9	99,3
35	Scenariusz 20%	0,0	18,5	44,2	-5,1	12,8	44,9	-0,4	15,7	46,6
	Scenariusz 50%	-3,5	41,5	125,4	0,0	33,0	125,4	2,8	37,9	125,4
	Scenariusz 80%	-11,2	74,0	229,9	0,0	62,7	236,8	9,3	69,8	238,0
	Scenariusz 100%	-16,9	109,0	329,0	0,0	95,8	339,7	14,5	103,4	346,9
	Scenariusz 120%	-20,9	147,9	416,5	0,0	135,2	443,3	22,6	141,8	450,3
	Scenariusz 150%	-22,0	176,5	502,5	1,2	167,2	532,8	24,3	171,4	550,7
40	Scenariusz 20%	-9,4	18,2	71,1	6,1	23,8	49,8	-1,2	16,4	39,8
	Scenariusz 50%	0,6	44,0	141,1	6,2	49,9	124,0	10,5	38,9	93,4
	Scenariusz 80%	15,3	81,3	220,0	9,3	89,5	250,3	17,1	75,1	183,1
	Scenariusz 100%	16,8	116,3	310,7	18,6	127,3	347,2	20,9	111,0	273,5
	Scenariusz 120%	19,0	147,2	380,7	29,7	169,4	473,1	24,4	149,1	368,8
	Scenariusz 150%	19,3	168,8	450,6	28,7	200,3	574,7	26,9	178,5	429,9
45	Scenariusz 20%	2,1	21,2	38,2	0,0	21,7	41,7	3,3	21,1	42,3
	Scenariusz 50%	5,9	44,4	93,4	5,7	46,3	94,1	9,0	48,0	95,9
	Scenariusz 80%	3,8	81,8	186,2	23,7	84,5	163,5	18,2	89,1	164,1
	Scenariusz 100%	3,7	118,5	303,9	39,9	124,2	220,7	33,8	130,2	223,6
	Scenariusz 120%	7,3	154,4	428,6	49,5	168,4	286,3	47,4	176,5	288,8
	Scenariusz 150%	-10,7	180,5	499,8	57,3	203,7	330,5	63,6	212,2	338,5
50	Scenariusz 20%	-5,5	43,6	85,9	6,4	39,2	73,4	1,9	33,8	73,3
	Scenariusz 50%	0,9	90,8	197,4	22,1	99,6	187,5	7,6	76,8	189,0
	Scenariusz 80%	7,8	159,0	352,0	41,1	185,1	344,0	18,0	140,5	353,4
	Scenariusz 100%	18,3	222,5	492,5	63,5	269,9	484,3	25,9	202,2	515,7
	Scenariusz 120%	26,6	294,3	671,4	97,5	360,0	652,7	29,6	273,3	719,1
	Scenariusz 150%	30,8	346,1	804,2	115,7	428,1	782,5	32,1	326,2	860,8
55	Scenariusz 20%	-0,1	26,4	53,9	-7,7	27,3	57,8	0,0	31,7	57,8
	Scenariusz 50%	21,6	58,2	123,8	-3,3	54,1	140,9	0,3	66,2	140,9

Liczba klientów	Zmienność	Średnia wartość różnicy w: Czas opóźnienia [min]								
		Gamma 5			Gamma 20			Gamma maks.		
		Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum
	Scenariusz 80%	54,5	109,3	247,0	-3,7	100,9	269,2	2,8	120,4	269,2
	Scenariusz 100%	72,0	167,9	403,4	-4,1	153,8	430,0	-1,9	179,6	429,4
	Scenariusz 120%	79,8	232,7	598,8	-2,5	219,7	632,0	-11,7	246,1	627,4
	Scenariusz 150%	72,8	285,2	779,0	4,4	274,1	808,0	-24,1	299,5	794,6
60	Scenariusz 20%	-11,2	26,2	61,3	-3,6	31,4	77,2	4,3	35,1	63,7
	Scenariusz 50%	-4,8	51,2	102,1	10,3	59,9	130,7	21,2	64,5	108,6
	Scenariusz 80%	8,9	91,1	174,4	28,9	103,1	203,2	49,5	108,2	197,4
	Scenariusz 100%	16,9	129,0	244,4	44,9	146,7	267,6	68,2	150,1	273,8
	Scenariusz 120%	22,7	172,6	343,0	51,3	200,6	349,6	78,2	202,1	341,6
	Scenariusz 150%	26,5	208,3	422,6	61,6	248,5	439,3	90,4	244,6	424,7
65	Scenariusz 20%	9,3	30,7	60,7	15,1	34,0	63,4	-85,1	15,1	62,6
	Scenariusz 50%	37,2	89,2	164,9	37,2	92,3	173,2	-48,4	72,2	173,2
	Scenariusz 80%	76,5	183,4	344,1	76,5	189,3	341,5	-14,7	165,8	320,9
	Scenariusz 100%	118,0	284,1	553,0	126,5	289,2	557,6	30,8	261,9	454,4
	Scenariusz 120%	156,8	398,9	768,4	186,9	411,4	795,2	85,5	378,1	676,6
	Scenariusz 150%	199,7	497,9	988,1	232,7	518,6	1009,8	126,9	478,9	860,7
70	Scenariusz 20%	-26,5	8,5	71,5	-3,8	38,2	64,7	-85,2	2,2	63,2
	Scenariusz 50%	-44,2	20,0	127,6	9,8	78,2	147,9	-69,2	38,4	126,6
	Scenariusz 80%	-60,5	40,5	183,3	19,9	139,3	319,4	-38,4	97,9	296,6
	Scenariusz 100%	-97,1	60,6	274,4	19,3	204,1	494,9	-0,9	163,0	474,4
	Scenariusz 120%	-160,7	79,4	402,0	35,4	278,6	694,8	20,8	235,1	676,3
	Scenariusz 150%	-177,8	92,3	500,9	51,1	331,7	837,8	38,2	286,2	821,1
75	Scenariusz 20%	11,3	56,9	150,7	28,0	71,4	152,2	-	-	-
	Scenariusz 50%	22,4	115,5	289,2	65,1	141,0	298,2	-	-	-
	Scenariusz 80%	63,0	197,7	471,2	97,6	239,1	490,1	-	-	-
	Scenariusz 100%	127,3	281,1	645,5	147,9	342,1	696,7	-	-	-
	Scenariusz 120%	181,7	367,9	843,8	213,8	456,8	936,0	-	-	-
	Scenariusz 150%	213,0	431,7	975,2	262,8	548,2	1128,4	-	-	-
80	Scenariusz 20%	29,0	85,2	352,9	41,1	90,4	349,5	-153,4	56,5	352,9
	Scenariusz 50%	63,8	176,0	604,0	63,8	190,1	598,3	-159,6	151,4	602,4
	Scenariusz 80%	108,0	310,1	896,1	108,2	338,2	904,6	-144,5	294,3	908,2
	Scenariusz 100%	157,7	435,3	1113,8	168,2	484,8	1160,6	-116,6	438,7	1166,4
	Scenariusz 120%	204,8	554,2	1310,3	242,2	640,4	1423,0	-74,5	592,4	1416,0
	Scenariusz 150%	232,2	645,7	1463,8	274,6	758,4	1629,8	-64,9	712,1	1611,5

Źródło: opracowanie własne.

PORÓWNANIE Z WARIANTEM STOCHASTYCZNYM

Czas przejazdu

Tabela B. 5 Minimalna, średnia oraz maksymalna wartość średniej różnicy czasu przejazdu pomiędzy rozwiązaniami w ujęciu stochastycznym, a rozwiązaniami w ujęciu odpornym na wahania parametrów modelu dla problemu VRP.

Liczba klientów	Zmienność	Średnia wartość różnicy w: Czas przejazdu [min]								
		$(1 - \alpha) = 65\%$			$(1 - \alpha) = 80\%$			$(1 - \alpha) = 95\%$		
		Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum
20	Scenariusz 60%	-11,4	5,5	24,9	-12,8	4,4	30,5	-14,2	3,8	12,7
	Scenariusz 100%	-12,5	8,3	30,7	-14,5	6,1	30,7	-10,8	7,3	17,7
	Scenariusz 120%	-12,6	9,8	35,2	-15,3	7,4	31,3	-8,9	9,2	20,7
	Scenariusz 140%	-12,6	10,6	36,7	-15,2	8,1	32,1	-7,7	10,2	22,0
	Scenariusz 160%	-12,7	11,7	39,4	-16,1	8,9	32,8	-6,6	11,6	23,7
25	Scenariusz 60%	-5,9	4,2	14,3	-5,8	4,9	17,9	-20,7	1,9	24,2
	Scenariusz 100%	-6,4	6,7	18,3	-3,3	7,2	21,7	-21,1	3,2	25,2
	Scenariusz 120%	-6,6	8,1	21,3	-2,5	8,5	24,8	-21,1	3,9	26,3
	Scenariusz 140%	-7,0	8,6	22,7	-2,2	9,0	26,5	-20,9	4,3	26,9
	Scenariusz 160%	-7,6	9,4	24,0	-1,6	9,9	28,9	-21,6	4,7	27,5
30	Scenariusz 60%	-8,7	16,1	42,0	-3,6	12,3	31,4	-7,8	7,1	33,3
	Scenariusz 100%	-10,5	17,5	43,8	-0,7	13,4	34,7	-7,1	7,4	34,4
	Scenariusz 120%	-11,4	18,0	44,6	-0,5	13,9	36,6	-7,0	7,4	34,8
	Scenariusz 140%	-12,1	18,2	45,1	-0,9	14,1	37,7	-7,2	7,5	35,2
	Scenariusz 160%	-12,7	18,6	45,8	-1,5	14,4	39,3	-7,8	7,5	35,6
35	Scenariusz 60%	-4,0	11,6	38,7	-11,7	10,3	31,4	3,7	14,8	33,0
	Scenariusz 100%	-4,6	13,9	44,8	-12,8	10,9	32,8	4,1	16,6	36,3
	Scenariusz 120%	-4,8	15,4	48,4	-13,3	11,3	33,0	3,9	17,6	38,7
	Scenariusz 140%	-5,0	16,0	50,2	-13,9	11,3	32,6	3,6	18,0	40,0
	Scenariusz 160%	-5,1	17,1	52,8	-14,0	11,8	32,9	3,3	18,9	41,8
40	Scenariusz 60%	-10,7	24,2	85,7	1,5	22,6	54,3	-20,5	5,0	38,7
	Scenariusz 100%	-9,2	26,3	87,0	1,1	25,4	56,8	-23,1	6,4	42,8
	Scenariusz 120%	-8,6	27,6	88,4	1,4	27,0	58,1	-24,6	7,4	46,5
	Scenariusz 140%	-8,1	28,2	89,2	1,7	27,8	59,5	-25,4	7,8	47,8
	Scenariusz 160%	-7,4	29,1	90,9	2,0	28,9	59,9	-27,2	8,4	50,1
45	Scenariusz 60%	-2,9	26,2	54,6	-11,4	17,6	63,5	-25,7	5,4	36,2
	Scenariusz 100%	-2,6	30,2	62,2	-11,6	20,6	71,7	-27,3	6,4	41,4
	Scenariusz 120%	-2,0	32,5	66,6	-11,4	22,5	76,7	-28,8	7,0	44,4
	Scenariusz 140%	-1,9	33,7	68,7	-11,3	23,4	78,6	-29,3	7,5	46,2
	Scenariusz 160%	-1,2	35,4	72,1	-11,0	24,6	81,7	-30,5	8,0	49,3
50	Scenariusz 60%	2,7	33,0	61,8	-40,4	20,0	56,6	-14,9	24,4	45,5
	Scenariusz 100%	4,1	36,6	67,3	-41,3	22,6	65,8	-15,1	27,0	51,9
	Scenariusz 120%	5,0	38,8	71,3	-42,3	24,4	71,2	-15,0	28,2	55,3
	Scenariusz 140%	5,1	39,7	72,1	-42,9	25,0	74,2	-15,3	28,9	56,8
	Scenariusz 160%	5,4	41,3	74,3	-44,4	26,0	78,0	-15,2	29,8	59,6
55	Scenariusz 60%	0,5	19,4	37,0	-5,2	15,8	46,6	-42,3	-2,2	24,0
	Scenariusz 100%	1,3	21,9	39,1	-2,1	19,0	52,7	-45,0	0,2	27,0
	Scenariusz 120%	1,5	23,4	41,1	-0,5	20,8	56,1	-46,6	1,3	28,6
	Scenariusz 140%	2,4	24,3	43,2	0,0	21,6	56,6	-47,1	1,9	29,3
	Scenariusz 160%	3,0	25,3	45,4	0,9	23,0	58,1	-48,3	2,6	30,5

Liczba klientów	Zmienność	Średnia wartość różnicy w: Czas przejazdu [min]								
		$(1 - \alpha) = 65\%$			$(1 - \alpha) = 80\%$			$(1 - \alpha) = 95\%$		
		Mini-mum	Średnia	Maksi-mum	Mini-mum	Średnia	Maksi-mum	Mini-mum	Średnia	Maksi-mum
60	Scenariusz 60%	-39,0	12,0	40,6	-13,0	27,2	53,0	-18,1	0,7	22,0
	Scenariusz 100%	-41,4	14,1	45,3	-13,0	31,1	56,1	-18,4	1,7	27,6
	Scenariusz 120%	-42,8	15,3	48,2	-12,2	32,8	57,9	-17,5	2,4	30,8
	Scenariusz 140%	-43,0	15,8	49,7	-11,3	33,8	58,9	-17,0	2,6	31,7
	Scenariusz 160%	-42,5	16,9	53,2	-10,2	35,2	60,2	-17,4	3,2	33,2
65	Scenariusz 60%	-18,2	16,1	45,8	-16,0	16,3	35,6	1,4	33,5	56,3
	Scenariusz 100%	-18,1	19,3	51,3	-17,4	18,1	37,7	4,5	37,7	62,5
	Scenariusz 120%	-17,7	21,0	54,2	-18,4	19,3	38,5	5,1	40,3	66,8
	Scenariusz 140%	-17,1	21,8	55,2	-19,2	19,7	39,3	4,9	41,5	69,6
	Scenariusz 160%	-16,0	23,6	57,5	-20,1	20,6	40,1	4,6	43,3	72,8
70	Scenariusz 60%	-14,6	2,6	21,5	-15,5	12,2	38,5	-35,3	10,0	49,3
	Scenariusz 100%	-16,1	2,9	20,6	-17,9	14,8	41,2	-38,8	10,9	53,7
	Scenariusz 120%	-17,8	2,6	18,4	-19,2	16,2	43,6	-41,2	11,6	56,5
	Scenariusz 140%	-18,5	2,8	18,4	-19,7	17,0	44,7	-41,6	12,3	57,6
	Scenariusz 160%	-19,6	3,2	18,1	-19,9	18,6	46,4	-42,3	13,2	59,9
75	Scenariusz 60%	-	-	-	-	-	-	-	-	-
	Scenariusz 100%	-	-	-	-	-	-	-	-	-
	Scenariusz 120%	-	-	-	-	-	-	-	-	-
	Scenariusz 140%	-	-	-	-	-	-	-	-	-
	Scenariusz 160%	-	-	-	-	-	-	-	-	-
80	Scenariusz 60%	-44,2	19,6	83,1	-49,4	4,9	30,1	-35,0	-2,4	36,9
	Scenariusz 100%	-45,2	22,2	91,6	-52,2	6,9	32,9	-37,7	-2,3	37,7
	Scenariusz 120%	-45,9	23,7	96,6	-53,1	8,3	36,1	-39,7	-2,4	37,6
	Scenariusz 140%	-46,1	24,6	100,0	-53,3	9,0	37,0	-40,6	-2,3	38,2
	Scenariusz 160%	-46,5	26,3	104,9	-54,0	10,0	39,0	-41,7	-2,1	38,4

Źródło: opracowanie własne.

Tabela B. 6 Minimalna, średnia oraz maksymalna wartość średniej redukcji czasu przejazdu pomiędzy rozwiązaniami w ujęciu stochastycznym, a rozwiązaniami w ujęciu odpornym na wahania parametrów modelu dla problemu VRP.

Liczba klientów	Zmienność	Średnia wartość redukcji w: Czas przejazdu [min]								
		$(1 - \alpha) = 65\%$			$(1 - \alpha) = 80\%$			$(1 - \alpha) = 95\%$		
		Mini-mum	Średnia	Maksi-mum	Mini-mum	Średnia	Maksi-mum	Mini-mum	Średnia	Maksi-mum
20	Scenariusz 60%	-11,1%	4,8%	22,3%	-15,3%	3,2%	23,1%	-16,6%	3,6%	13,0%
	Scenariusz 100%	-10,6%	6,6%	24,9%	-15,9%	4,4%	21,9%	-11,7%	6,2%	16,0%
	Scenariusz 120%	-10,3%	7,4%	26,9%	-16,0%	5,1%	21,9%	-9,4%	7,4%	17,7%
	Scenariusz 140%	-10,2%	7,7%	27,3%	-15,6%	5,5%	22,1%	-8,1%	8,0%	18,3%
	Scenariusz 160%	-10,0%	8,2%	28,0%	-16,1%	5,9%	22,3%	-7,0%	8,6%	18,8%
25	Scenariusz 60%	-6,3%	3,4%	12,0%	-6,8%	3,7%	15,5%	-24,9%	-0,6%	18,1%
	Scenariusz 100%	-6,3%	5,0%	13,5%	-3,1%	5,2%	16,3%	-23,4%	0,5%	17,6%
	Scenariusz 120%	-6,4%	5,8%	15,0%	-2,3%	5,9%	16,6%	-22,5%	1,0%	17,6%
	Scenariusz 140%	-6,7%	6,0%	15,5%	-2,0%	6,2%	16,8%	-21,8%	1,2%	17,6%
	Scenariusz 160%	-7,1%	6,3%	15,7%	-1,6%	6,5%	17,9%	-21,9%	1,4%	17,5%
30	Scenariusz 60%	-12,1%	13,2%	31,1%	-1,5%	10,9%	29,9%	-7,2%	5,4%	26,1%
	Scenariusz 100%	-11,9%	13,4%	31,4%	-1,0%	11,0%	29,6%	-6,9%	5,6%	26,5%
	Scenariusz 120%	-11,3%	13,5%	31,6%	-0,6%	11,1%	29,3%	-7,2%	5,6%	26,6%
	Scenariusz 140%	-10,8%	13,7%	32,1%	-0,9%	11,2%	28,9%	-7,6%	5,9%	27,2%
	Scenariusz 160%	-9,4%	13,6%	32,9%	-4,4%	11,1%	28,2%	-8,8%	6,1%	28,1%
35	Scenariusz 60%	-3,6%	9,1%	27,7%	-12,3%	6,9%	21,2%	3,1%	11,3%	24,6%
	Scenariusz 100%	-3,8%	9,9%	29,0%	-12,4%	6,7%	20,5%	3,0%	11,6%	24,9%
	Scenariusz 120%	-4,0%	10,6%	30,1%	-12,7%	6,5%	19,2%	2,4%	11,7%	25,6%
	Scenariusz 140%	-3,9%	10,5%	29,7%	-12,4%	6,7%	19,7%	2,7%	11,7%	25,4%
	Scenariusz 160%	-3,9%	10,9%	30,6%	-12,5%	6,6%	18,7%	2,1%	11,9%	25,9%
40	Scenariusz 60%	-7,6%	12,5%	41,3%	1,0%	13,3%	30,8%	-15,2%	2,4%	24,1%
	Scenariusz 100%	-6,2%	12,9%	39,8%	0,7%	13,9%	30,1%	-16,1%	2,8%	24,5%
	Scenariusz 120%	-5,5%	13,1%	39,2%	0,8%	14,2%	29,8%	-16,7%	3,1%	25,3%
	Scenariusz 140%	-5,1%	13,2%	39,0%	1,0%	14,3%	29,9%	-17,0%	3,2%	25,5%
	Scenariusz 160%	-4,6%	13,3%	38,8%	1,1%	14,5%	29,4%	-17,9%	3,3%	25,8%
45	Scenariusz 60%	-1,6%	15,0%	30,9%	-7,0%	9,9%	34,8%	-18,6%	2,5%	22,9%
	Scenariusz 100%	-1,4%	15,7%	31,7%	-6,5%	10,4%	35,7%	-18,4%	2,8%	23,9%
	Scenariusz 120%	-1,1%	16,0%	32,2%	-6,1%	10,8%	36,2%	-18,6%	2,9%	24,4%
	Scenariusz 140%	-1,1%	16,2%	32,5%	-5,9%	11,0%	36,2%	-18,5%	3,0%	24,6%
	Scenariusz 160%	-0,8%	16,4%	32,9%	-5,6%	11,1%	36,4%	-18,7%	3,0%	25,0%
50	Scenariusz 60%	1,2%	15,3%	28,6%	-24,5%	8,4%	26,7%	-7,7%	11,7%	22,8%
	Scenariusz 100%	1,7%	15,5%	28,6%	-22,8%	8,7%	25,7%	-7,1%	11,8%	23,6%
	Scenariusz 120%	1,9%	15,6%	28,5%	-22,0%	9,0%	25,2%	-6,9%	11,7%	24,0%
	Scenariusz 140%	1,9%	15,6%	28,8%	-22,3%	8,9%	25,0%	-6,9%	11,7%	23,9%
	Scenariusz 160%	1,9%	15,7%	28,5%	-22,1%	9,0%	25,6%	-6,7%	11,6%	24,3%
55	Scenariusz 60%	0,3%	9,6%	17,3%	-3,1%	7,6%	21,0%	-32,6%	-2,9%	12,9%
	Scenariusz 100%	0,6%	10,0%	16,8%	-1,2%	8,4%	21,8%	-31,8%	-1,7%	13,2%
	Scenariusz 120%	0,7%	10,1%	17,0%	-0,4%	8,8%	22,1%	-31,3%	-1,2%	13,3%
	Scenariusz 140%	1,0%	10,3%	17,4%	-0,1%	9,0%	21,8%	-31,0%	-1,0%	13,3%
	Scenariusz 160%	1,3%	10,3%	17,7%	0,3%	9,2%	21,7%	-30,8%	-0,8%	13,3%
60	Scenariusz 60%	-25,6%	5,1%	20,9%	-7,3%	12,8%	25,7%	-10,5%	-0,1%	11,0%
	Scenariusz 100%	-25,1%	5,6%	21,1%	-6,8%	13,5%	24,9%	-9,9%	0,3%	12,6%
	Scenariusz 120%	-25,0%	5,7%	21,4%	-6,1%	13,6%	24,6%	-9,5%	0,6%	13,5%
	Scenariusz 140%	-24,7%	5,8%	21,5%	-5,6%	13,7%	24,5%	-9,4%	0,6%	13,6%

Liczba klientów	Zmienność	Średnia wartość redukcji w: Czas przejazdu [min]								
		$(1 - \alpha) = 65\%$			$(1 - \alpha) = 80\%$			$(1 - \alpha) = 95\%$		
		Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum
65	Scenariusz 160%	-23,7%	6,0%	22,1%	-4,9%	13,9%	24,4%	-9,4%	0,9%	13,8%
	Scenariusz 60%	-9,8%	6,1%	18,4%	-8,1%	6,8%	14,7%	0,6%	13,3%	19,8%
	Scenariusz 100%	-8,9%	6,8%	18,7%	-8,2%	6,9%	14,3%	1,7%	13,7%	20,2%
	Scenariusz 120%	-8,3%	7,0%	19,1%	-8,4%	6,9%	14,0%	1,9%	13,9%	20,5%
	Scenariusz 140%	-7,9%	7,2%	19,2%	-8,5%	6,9%	13,9%	1,7%	14,0%	20,8%
70	Scenariusz 160%	-7,2%	7,6%	19,6%	-8,8%	7,0%	13,7%	1,5%	14,1%	21,1%
	Scenariusz 60%	-7,6%	1,1%	9,2%	-7,9%	4,9%	14,4%	-16,1%	3,8%	17,8%
	Scenariusz 100%	-7,8%	1,1%	8,2%	-8,6%	5,5%	14,3%	-16,4%	3,7%	17,9%
	Scenariusz 120%	-8,3%	0,9%	7,1%	-8,9%	5,7%	14,5%	-16,8%	3,7%	18,0%
	Scenariusz 140%	-8,4%	0,9%	7,0%	-9,0%	5,8%	14,6%	-16,7%	3,9%	18,0%
75	Scenariusz 160%	-8,7%	1,0%	6,6%	-8,8%	6,2%	14,7%	-16,5%	4,1%	18,2%
	Scenariusz 60%	-	-	-	-	-	-	-	-	-
	Scenariusz 100%	-	-	-	-	-	-	-	-	-
	Scenariusz 120%	-	-	-	-	-	-	-	-	-
	Scenariusz 140%	-	-	-	-	-	-	-	-	-
80	Scenariusz 160%	-	-	-	-	-	-	-	-	-
	Scenariusz 60%	-18,3%	6,1%	26,8%	-25,2%	0,6%	12,0%	-14,6%	-1,6%	14,0%
	Scenariusz 100%	-17,1%	6,3%	26,6%	-24,3%	1,0%	11,7%	-13,8%	-1,5%	13,0%
	Scenariusz 120%	-16,5%	6,4%	26,6%	-23,5%	1,4%	12,2%	-14,0%	-1,4%	12,3%
	Scenariusz 140%	-16,2%	6,4%	26,8%	-23,0%	1,5%	12,2%	-14,0%	-1,4%	12,2%
Scenariusz 160%	-15,8%	6,7%	26,9%	-22,5%	1,7%	12,3%	-14,0%	-1,4%	11,9%	

Źródło: opracowanie własne.

Czas wczesnego przyjazdu

Tabela B. 7 Minimalna, średnia oraz maksymalna wartość średniej różnicy czasu wczesnego przejazdu pomiędzy rozwiązaniami w ujęciu deterministycznym, a rozwiązaniami w ujęciu odpornym na wahania parametrów modelu dla problemu VRP.

Liczba klientów	Zmienność	Średnia wartość różnicy w: Czas wczesnego przejazdu [min]								
		$(1 - \alpha) = 65\%$			$(1 - \alpha) = 80\%$			$(1 - \alpha) = 95\%$		
		Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum
20	Scenariusz 60%	-109,2	-33,7	0,7	-40,5	35,4	86,6	-114,6	-48,5	-13,5
	Scenariusz 100%	-90,4	-28,1	1,0	-36,4	21,6	62,9	-92,4	-37,8	-11,4
	Scenariusz 120%	-79,9	-24,8	1,2	-34,4	15,1	52,3	-81,3	-32,6	-10,1
	Scenariusz 140%	-75,0	-23,2	1,1	-33,5	12,3	47,6	-76,1	-30,3	-9,4
	Scenariusz 160%	-67,9	-20,9	1,2	-32,1	8,9	41,3	-68,6	-26,9	-8,4
25	Scenariusz 60%	-46,9	-25,3	-8,7	-40,1	-5,1	16,3	10,4	100,9	243,8
	Scenariusz 100%	-50,3	-27,7	-10,7	-47,6	-4,3	20,2	9,5	105,8	254,3
	Scenariusz 120%	-52,5	-29,2	-12,3	-53,1	-3,5	23,2	9,1	109,1	261,8
	Scenariusz 140%	-57,7	-32,1	-12,5	-67,4	-1,7	32,1	8,0	115,9	276,8
	Scenariusz 160%	-79,7	-35,5	-5,2	-91,0	3,2	52,2	5,3	129,6	303,4
30	Scenariusz 60%	-15,1	4,5	25,5	3,0	17,9	42,4	8,6	84,5	195,2
	Scenariusz 100%	-14,4	5,5	26,4	4,4	19,8	44,4	9,5	91,5	213,1
	Scenariusz 120%	-13,9	6,2	27,2	4,9	21,3	45,8	10,1	96,3	225,6
	Scenariusz 140%	-11,6	8,4	29,6	5,8	24,7	50,1	11,5	106,2	249,6
	Scenariusz 160%	-7,2	13,6	35,8	4,6	31,2	57,6	14,6	125,5	301,1
35	Scenariusz 60%	-53,4	-33,0	-0,7	-32,1	-7,6	24,6	48,0	114,8	218,6
	Scenariusz 100%	-60,0	-35,5	-0,5	-33,9	-7,0	29,8	49,8	122,7	233,7
	Scenariusz 120%	-65,2	-37,2	-0,2	-35,4	-6,7	33,3	50,7	127,5	242,3
	Scenariusz 140%	-75,6	-40,1	1,0	-38,4	-5,5	40,7	51,9	137,5	266,8
	Scenariusz 160%	-95,9	-43,6	7,3	-44,3	-2,4	60,5	55,3	155,6	317,4
40	Scenariusz 60%	-93,8	-45,9	-16,8	-46,1	-9,0	27,0	28,0	160,1	331,1
	Scenariusz 100%	-101,8	-49,8	-19,8	-49,1	-8,6	29,7	30,7	167,2	346,6
	Scenariusz 120%	-107,3	-52,6	-22,1	-51,4	-8,2	31,1	32,5	172,4	358,2
	Scenariusz 140%	-119,2	-57,9	-26,8	-53,5	-6,5	34,5	36,4	182,9	382,8
	Scenariusz 160%	-138,9	-66,6	-34,7	-54,7	-1,5	42,9	43,6	201,6	424,4
45	Scenariusz 60%	-100,6	-64,1	-35,9	-54,9	-16,1	26,1	79,4	138,3	258,3
	Scenariusz 100%	-106,6	-69,3	-38,8	-57,7	-14,2	35,4	83,7	145,9	277,1
	Scenariusz 120%	-110,6	-72,7	-40,5	-59,1	-12,4	41,5	84,5	151,4	291,0
	Scenariusz 140%	-117,0	-78,8	-43,3	-62,2	-7,7	56,6	86,2	161,8	319,0
	Scenariusz 160%	-125,2	-87,1	-45,7	-59,8	4,7	91,4	92,5	182,7	375,4
50	Scenariusz 60%	-154,7	-86,3	-28,8	-66,8	-9,0	24,6	131,2	257,1	560,7
	Scenariusz 100%	-171,8	-96,3	-29,9	-73,9	-7,4	37,1	130,7	270,2	592,0
	Scenariusz 120%	-182,4	-103,7	-30,4	-80,0	-6,1	47,7	128,2	278,9	613,1
	Scenariusz 140%	-204,5	-117,8	-31,3	-92,7	-1,2	75,3	125,9	295,5	651,7
	Scenariusz 160%	-240,4	-142,7	-33,1	-118,3	8,9	112,1	121,1	326,8	717,2
55	Scenariusz 60%	-210,1	-118,8	-35,5	-122,8	-19,5	58,0	121,7	262,4	389,7
	Scenariusz 100%	-170,3	-96,0	-29,6	-92,2	-19,8	40,7	131,8	238,0	348,0
	Scenariusz 120%	-146,9	-83,5	-25,7	-77,4	-19,5	32,8	136,4	224,6	322,1
	Scenariusz 140%	-135,3	-77,6	-24,0	-70,7	-19,3	27,6	132,3	217,9	308,0
	Scenariusz 160%	-118,1	-68,9	-21,8	-61,0	-19,0	20,9	126,5	208,4	288,5
60	Scenariusz 60%	-197,9	-121,2	-85,8	-105,4	-47,5	28,6	83,6	163,9	279,9
	Scenariusz 100%	-161,8	-101,7	-71,4	-92,7	-44,9	10,7	92,5	155,1	239,4

		Średnia wartość różnicy w: Czas wczesnego przejazdu [min]								
Liczba klientów	Zmienność	$(1 - \alpha) = 65\%$			$(1 - \alpha) = 80\%$			$(1 - \alpha) = 95\%$		
		Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum
	Scenariusz 120%	-140,8	-90,9	-61,7	-84,5	-41,9	6,1	94,3	149,0	225,2
	Scenariusz 140%	-131,8	-86,0	-57,8	-81,4	-40,5	3,7	94,5	145,3	218,7
	Scenariusz 160%	-118,3	-78,8	-51,6	-76,3	-38,1	1,5	93,5	140,0	209,3
65	Scenariusz 60%	-278,4	-108,3	-56,5	-219,0	-49,8	13,3	186,7	278,3	424,3
	Scenariusz 100%	-298,3	-117,8	-63,1	-228,2	-49,7	20,5	194,7	298,3	466,8
	Scenariusz 120%	-312,5	-124,4	-67,5	-234,4	-49,6	25,8	199,9	312,6	500,1
	Scenariusz 140%	-339,4	-137,7	-76,2	-243,5	-48,5	37,3	214,8	342,9	569,0
	Scenariusz 160%	-377,5	-158,8	-92,0	-249,8	-41,7	63,2	249,9	397,3	700,2
70	Scenariusz 60%	-196,0	-134,4	-82,5	-125,3	-36,5	35,4	142,6	202,5	260,6
	Scenariusz 100%	-159,2	-113,0	-70,9	-95,5	-32,2	30,3	128,5	188,3	226,0
	Scenariusz 120%	-141,2	-99,8	-62,4	-84,7	-28,7	29,2	119,3	180,5	208,8
	Scenariusz 140%	-134,8	-93,6	-58,9	-79,9	-27,3	28,3	115,1	175,8	202,9
	Scenariusz 160%	-126,0	-85,1	-53,4	-73,8	-25,6	25,2	109,5	169,1	200,9
75	Scenariusz 60%	-	-	-	-	-	-	-	-	-
	Scenariusz 100%	-	-	-	-	-	-	-	-	-
	Scenariusz 120%	-	-	-	-	-	-	-	-	-
	Scenariusz 140%	-	-	-	-	-	-	-	-	-
	Scenariusz 160%	-	-	-	-	-	-	-	-	-
80	Scenariusz 60%	-313,8	-240,2	-142,2	-177,9	-90,3	14,1	146,7	369,9	595,2
	Scenariusz 100%	-244,1	-191,5	-116,6	-148,4	-81,4	16,4	165,5	339,8	526,1
	Scenariusz 120%	-210,7	-165,2	-103,8	-128,0	-73,8	13,9	173,9	321,7	484,3
	Scenariusz 140%	-194,0	-152,8	-97,8	-117,7	-69,2	11,0	176,6	311,8	463,3
	Scenariusz 160%	-170,9	-136,0	-88,9	-109,2	-62,1	9,4	178,0	297,3	433,8

Źródło: opracowanie własne.

Czas opóźnienia

Tabela B. 8 Minimalna, średnia oraz maksymalna wartość średniej różnicy czasu opóźnienia pomiędzy rozwiązaniami w ujęciu deterministycznym, a rozwiązaniami w ujęciu odpornym na wahania parametrów modelu dla problemu VRP.

Liczba klientów	Zmienność	Średnia wartość różnicy w: Czas opóźnienia [min]								
		$(1 - \alpha) = 65\%$			$(1 - \alpha) = 80\%$			$(1 - \alpha) = 95\%$		
		Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum
20	Scenariusz 60%	-7,6	-1,2	12,6	-6,6	-0,1	7,4	-3,8	10,6	24,8
	Scenariusz 100%	-7,5	-0,4	15,6	-4,8	0,1	7,3	-4,2	14,3	34,9
	Scenariusz 120%	-6,2	1,3	19,3	-4,7	0,4	7,6	-4,2	17,0	41,9
	Scenariusz 140%	-5,4	2,4	21,3	-4,6	0,6	8,5	-4,2	18,4	45,3
	Scenariusz 160%	-3,9	4,4	25,8	-4,8	0,9	10,4	-4,2	20,8	50,8
25	Scenariusz 60%	-2,3	2,9	13,2	0,0	2,9	14,8	-2,3	-0,2	0,0
	Scenariusz 100%	-4,6	4,8	16,2	0,0	3,1	14,4	-4,6	-0,5	0,0
	Scenariusz 120%	-5,7	6,8	18,7	-0,2	3,2	14,2	-6,0	-0,6	0,0
	Scenariusz 140%	-6,0	8,2	20,7	-0,5	3,3	14,1	-6,7	-0,8	0,0
	Scenariusz 160%	-6,4	10,5	24,4	-1,2	3,3	14,0	-7,7	-1,0	0,0
30	Scenariusz 60%	-60,5	-15,8	15,2	-74,1	-24,6	24,4	-74,3	-27,3	6,8
	Scenariusz 100%	-52,7	-14,7	14,4	-63,9	-21,6	24,2	-64,0	-24,0	6,8
	Scenariusz 120%	-47,8	-13,8	13,9	-57,8	-19,8	24,1	-57,8	-22,0	6,8
	Scenariusz 140%	-38,5	-12,2	13,0	-45,8	-16,3	23,9	-45,8	-18,2	6,7
	Scenariusz 160%	-24,4	-9,3	11,7	-27,9	-11,0	23,4	-27,9	-12,4	6,5
35	Scenariusz 60%	3,4	7,8	17,4	-5,6	-0,4	1,2	-9,8	-2,0	0,0
	Scenariusz 100%	2,9	12,7	21,1	-2,6	0,5	3,0	-12,2	-2,3	0,0
	Scenariusz 120%	2,7	17,6	23,8	-0,7	1,1	4,8	-13,4	-2,7	0,0
	Scenariusz 140%	2,9	20,9	30,9	-1,0	1,5	6,4	-14,0	-2,9	0,0
	Scenariusz 160%	3,3	26,7	43,6	-1,8	2,0	9,3	-14,8	-3,3	0,0
40	Scenariusz 60%	0,0	13,2	27,1	-3,1	2,5	18,5	-11,8	-1,0	11,8
	Scenariusz 100%	0,6	18,1	34,3	0,0	3,3	18,4	-13,4	-1,1	12,8
	Scenariusz 120%	1,2	22,1	41,0	0,0	3,9	18,2	-14,3	-1,2	13,5
	Scenariusz 140%	1,8	24,5	44,3	0,0	4,1	17,8	-14,8	-1,3	13,8
	Scenariusz 160%	3,1	28,8	49,7	0,0	4,5	17,1	-15,5	-1,5	14,1
45	Scenariusz 60%	-6,9	6,5	28,1	-5,9	2,2	12,8	-11,9	-2,4	1,7
	Scenariusz 100%	-6,0	9,6	36,5	-6,5	2,5	15,5	-12,4	-3,3	1,7
	Scenariusz 120%	-2,8	13,3	44,5	-6,8	2,7	17,1	-12,8	-3,9	1,6
	Scenariusz 140%	-0,5	15,7	49,4	-6,8	2,9	18,0	-13,1	-4,3	1,5
	Scenariusz 160%	3,7	19,9	57,1	-6,6	3,0	18,7	-13,6	-4,8	1,4
50	Scenariusz 60%	-15,5	1,5	19,3	-19,2	-2,3	7,8	-20,4	-1,3	15,3
	Scenariusz 100%	-3,1	7,4	33,5	-17,3	-2,3	8,3	-22,0	-2,2	14,2
	Scenariusz 120%	-1,4	14,2	47,4	-15,9	-2,2	9,3	-23,0	-2,9	13,6
	Scenariusz 140%	0,8	18,4	56,1	-15,2	-2,0	10,0	-23,4	-3,3	13,4
	Scenariusz 160%	5,9	26,5	71,7	-14,1	-1,3	10,8	-24,1	-3,9	12,9
55	Scenariusz 60%	-2,1	7,2	12,9	-8,4	1,1	19,6	-2,8	0,0	3,4
	Scenariusz 100%	8,1	14,8	24,0	-11,1	1,4	22,8	-2,9	-0,1	3,9
	Scenariusz 120%	13,4	22,4	41,4	-13,3	1,5	24,7	-2,6	-0,2	4,1
	Scenariusz 140%	14,3	27,5	53,4	-14,4	1,6	25,5	-2,4	-0,4	4,3
	Scenariusz 160%	15,8	35,5	72,5	-14,9	2,1	26,7	-3,4	-0,6	4,5
60	Scenariusz 60%	-18,3	2,0	15,6	-19,5	3,2	13,3	-19,5	-6,6	0,0
	Scenariusz 100%	-10,9	7,5	23,5	-18,7	4,2	15,6	-20,0	-7,9	0,1

		Średnia wartość różnicy w: Czas opóźnienia [min]								
Liczba klientów	Zmienność	$(1 - \alpha) = 65\%$			$(1 - \alpha) = 80\%$			$(1 - \alpha) = 95\%$		
		Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum	Minimum	Średnia	Maksimum
	Scenariusz 120%	-2,8	13,2	29,9	-16,2	5,4	18,7	-20,3	-8,6	0,2
	Scenariusz 140%	2,2	16,8	33,9	-14,3	6,2	20,5	-20,4	-9,0	0,3
	Scenariusz 160%	5,0	23,2	41,3	-11,3	7,6	23,4	-20,6	-9,7	0,1
65	Scenariusz 60%	-22,5	2,5	23,5	-18,1	6,3	24,9	-24,5	-9,2	0,0
	Scenariusz 100%	-17,1	6,7	32,5	-15,4	5,7	22,9	-30,5	-11,2	0,0
	Scenariusz 120%	-7,5	12,5	40,6	-13,8	5,0	22,2	-39,6	-13,0	0,0
	Scenariusz 140%	-6,0	16,7	46,3	-12,8	4,7	21,9	-45,6	-14,2	0,0
	Scenariusz 160%	-5,6	24,7	54,7	-11,0	4,1	21,8	-56,0	-16,2	-0,2
70	Scenariusz 60%	1,9	14,7	26,8	-12,6	5,6	37,6	-11,6	-5,5	0,0
	Scenariusz 100%	5,7	22,9	43,2	-12,4	7,5	41,2	-12,9	-6,6	0,0
	Scenariusz 120%	10,4	30,4	54,7	-12,3	8,8	43,2	-15,2	-7,3	-0,2
	Scenariusz 140%	13,5	35,2	61,2	-12,0	9,6	44,2	-16,4	-7,7	-0,5
	Scenariusz 160%	18,8	43,4	71,5	-11,4	10,9	45,6	-18,3	-8,3	-0,8
75	Scenariusz 60%	-	-	-	-	-	-	-	-	-
	Scenariusz 100%	-	-	-	-	-	-	-	-	-
	Scenariusz 120%	-	-	-	-	-	-	-	-	-
	Scenariusz 140%	-	-	-	-	-	-	-	-	-
	Scenariusz 160%	-	-	-	-	-	-	-	-	-
80	Scenariusz 60%	1,8	14,5	28,9	-0,4	5,5	20,7	0,0	0,0	0,0
	Scenariusz 100%	8,2	30,1	48,0	-2,8	7,7	27,6	-2,3	-0,6	0,0
	Scenariusz 120%	17,5	44,3	76,3	-5,0	8,9	31,6	-6,3	-1,7	0,0
	Scenariusz 140%	24,3	53,2	96,1	-6,4	9,5	33,8	-8,7	-2,5	-0,1
	Scenariusz 160%	39,3	69,2	129,7	-8,4	10,9	36,5	-12,5	-3,8	-0,5

Źródło: opracowanie własne.