

Politechnika Gdańska
Wydział Zarządzania i Ekonomii

**Analiza skutków ekonomicznych
zastosowania wybranych metaheurystyk
w harmonogramowaniu projektów**

Rozprawa doktorska

Adam Kostrubiec

*Katedra Inżynierii Systemów Produkcji
Politechnika Gdańska*

Promotor:

prof. zw. dr hab. Piotr Jędrzejowicz

*Katedra Systemów Informatycznych
Akademia Morska w Gdyni*

Gdańsk, wrzesień 2007

Doctoral dissertation:

**The Analysis of Economical Effects of Implementation of Selected Metaheuristics
in Project Scheduling**

by Adam Kostrubiec

Department of Engineering of Production Systems, Gdansk University of Technology

Submitted to:

Gdansk University of Technology, Faculty of Management and Economics

Supervisor:

prof. dr hab. Piotr Jędrzejowicz

Department of Information Systems, Gdynia Maritime Academy

Gdansk, September 2007

Streszczenie

Rozprawa dotyczy problematyki związanej z budowaniem harmonogramów realizacji prac w organizacjach zarządzanych przez projekty. W ostatnich latach można zauważyć rosnące zainteresowanie tą formą wytwarzania i dostarczania zarówno dóbr inwestycyjnych, jak i konsumpcyjnych w rozmaitych gałęziach gospodarki. Niezależnie od charakteru projektu, struktury jego finansowania, czy celów gospodarczych, zawsze jest on związany z poniesieniem w czasie określonych wydatków związanych z zaangażowaniem rozmaitych zasobów (m. in. maszyn, środków transportu, materiałów, czy pracowników), zakupem energii czy usług, zarówno materialnych jak i niematerialnych. Harmonogram stanowiąc jedno z istotniejszych narzędzi pozwalających na właściwe zarządzanie (w zakresie planowania, organizowania i kontroli) realizacją przedsięwzięcia, zwiększa szanse uzyskania satysfakcjonującego efektu w zaplanowanym terminie i w ramach zatwierdzonego budżetu. Wobec istotnej roli harmonogramu, pojawia się pytanie o możliwość jego optymalizacji z uwzględnieniem czynników ekonomicznych opartej na nowoczesnych metaheurystykach.

Występują trzy zasadnicze przesłanki do przeprowadzenia niniejszej pracy. Po pierwsze większość stosowanych komputerowych systemów wspomagających zarządzanie projektami nie oferuje możliwości optymalizacji harmonogramu umożliwiając jedynie jego zbudowanie i ocenę jakości. Z drugiej strony mankamentem większości istniejących metod optymalizacji możliwych do zastosowania w oprogramowaniu dla zarządzania projektami jest znaczny stopień uproszczenia modelu przedsięwzięcia i ukierunkowanie go na kryteria czasowe, których stosowanie dla oceny działalności gospodarczej jest niewystarczające. W takim przypadku, można zauważyć, że ocena skutków ekonomicznych wykonywana jest po zbudowaniu harmonogramu jako konsekwencja przyjętych rozwiązań, zamiast analizy efektów ekonomicznych już na etapie procesu decyzyjnego. Po trzecie można zaobserwować rosnące zainteresowanie i liczne sukcesy zarówno w zakresie badań naukowych jak i praktycznego zastosowania metaheurystyk.

Pracę otwiera rozdział poświęcony definicjom oraz podstawowym pojęciom w zakresie zarządzania projektami i harmonogramowania. Kolejno przedstawiono klasyfikację problemów harmonogramowania projektów ze względu na stosowane kryteria oceny oraz zakres występujących ograniczeń. Następnie przedstawiono przegląd napotkanych w literaturze metod optymalizacji harmonogramów, w tym: algorytmów dokładnych, heurystyk priorytetowych oraz metaheurystyk. W rozdziale 3 przeanalizowano metody oceny jakości harmonogramu projektu z uwzględnieniem czynników organizacyjnych i ekonomicznych. Przedstawiono wpływ poszczególnych zmiennych decyzyjnych w procesie harmonogramowania na poszczególne kryteria czasowe i ekonomiczne. W rozdziale 4 sformułowano model harmonogramowania projektów uwzględniający ekonomiczny charakter projektu oraz pozwalający na możliwie dokładne opisanie zależności pomiędzy zmiennymi decyzyjnymi, a ich skutkami ekonomicznymi. Sformułowano ograniczenia zmiennych decyzyjnych oraz dynamiczne kryteria oceny efektywności ekonomicznej harmonogramu. Rozdział 5 poświęcono analizie technik występujących w ramach metod dokładnych i heurystycznych, które mogą znaleźć zastosowanie w badanych procedurach z uwzględnieniem skonstruowanego uprzednio modelu. Przedstawiono dostępne sposoby reprezentacji problemu, procedury budowy harmonogramów, techniki eksplorujące i eksploatujące oraz stosowane strategie kierowania poszukiwaniem w ramach algorytmu genetycznego, symulowanego wyżarzania, poszukiwania z ruchami zabronionymi, poszukiwania rozproszonego oraz algorytmu uczenia populacji. W rozdziale 6 przedstawiono opis założeń i wyników z przeprowadzonych eksperymentów obliczeniowych w możliwie szerokiej grupie problemów przy reprezentatywnym zestawie parametrów procedur. Pracę zamyka podsumowanie uzyskanych wyników oraz wskazanie kierunków prowadzenia dalszych badań.

Badania algorytmu genetycznego, symulowanego wyżarzania, poszukiwania z ruchami zabronionymi i algorytmu hybrydowego (łąającego cechy algorytmu genetycznego i symulowanego wyżarzania) w grupie

problemów o zróżnicowanym rozmiarze i ścisłości ograniczeń potwierdziły istnienie efektywnej możliwości optymalizacji harmonogramu projektu opartej na nowoczesnych metaheurystykach. Dodatkowo stwierdzono, że optymalizacja ukierunkowana na kryteria czasowe nie gwarantuje zadowalających efektów ekonomicznych. Natomiast na *trudność* problemu największy wpływ ma liczba zadań i ścisłość ograniczeń zasobowych. Opracowany model harmonogramowania projektów pozwala na integrację z różnego rodzaju systemami komputerowymi, co może stać się kierunkiem dalszych badań.

Abstract

The dissertation concerns problems related to building project schedules in organizations managed by projects. In preceding years, the increasing interest in this form of production and supply of both capital and consumer goods in various branches of economies could be noticed. Regardless of character, its capital structure or economic goals, a project always causes expenses related to the usage of different resources (e.g. machines, means of transport, materials, or manpower), the energy consumption or buying services, both material and non-material. The schedule as the one of the most important instruments in the proper management (within the scope of planning, organization and control) of realization of project, increases the chances of achieving the satisfying effect in the planned deadline and within the approved budget. Because of the importance of this tool there comes a question if it is possible to optimize the schedule due to the economic factors based on the modern metaheuristics.

There are three fundamental premises to conduct this work. Most of the computer based project management support systems do not give the possibility of optimization of the schedule, enabling only its building and evaluating. On the other hand, the drawbacks of most of the optimization methods applicable to the software are: high level of the model simplification and time criteria direction, which is unsatisfactory for evaluation of economic activity. In such a case, it can be noticed that estimation of the economic result is a consequence of accepted solution after building the schedule, instead of analysis of economic effect during decision process. We can also observe the increasing interest and remarkable progress in the area of scientific research and practical implementation of metaheuristics.

The dissertation starts with the chapter devoted to basic notions and definitions related to the project management area and scheduling. Secondly, we present the classification of project scheduling problems from the perspective of constraints and evaluation criteria. Next, we introduce the review of optimization methods, including: exact algorithms, priority heuristics and metaheuristics. In chapter 3 we analyze the evaluation of the project schedule quality, both organizational and economic. We present the influence of each decision variable on time and value criteria in the scheduling process. In chapter 4 we formulate the model of project scheduling with economic factors which allows to describe the relations between decision variables and economic effects in the precise way. The constraints of the decision variables and the dynamic criteria of economic effects of schedule estimation are formulated as well. Chapter 5 deals with the analysis of detailed procedures of the exact and heuristic methods, that can be used in the examined algorithms regarding to the previously constructed model. We present available representation schemes, schedule generation procedures, exploration and exploitation techniques and searching strategies in the genetic algorithm, simulated annealing, tabu search, scatter search and population learning algorithm. In chapter 6, the description of assumptions and results of computational experiments in the possibly wide group of problems with the representative procedures' parameters is presented. The dissertation is concluded by the summary of the results and the directions of further research.

The examination of genetic algorithm, simulated annealing, tabu search and hybrid algorithm (combining features of genetic algorithm and simulated annealing) in the group of different size and complexity of problems has confirmed that there is an interesting possibility to improve the project schedules effectively by the usage of modern metaheuristics. We noticed also that the optimization of time criteria does not guarantee good economic effects. We have proved that the *hardness* (or computational complexity) of the problem highly depends on the number of activities and restrictiveness of the resource constraints. The topology of project network is observed to have less importance. The model of project scheduling formulated during the research is found elastic and applicable to the different kinds of project management support systems, what can be direction of further research.

Spis treści

1	Wstęp	1
1.1	Opis problemu	1
1.2	Cel pracy i hipotezy badawcze	2
1.3	Metoda realizacji pracy	2
2	Harmonogramowanie realizacji projektów	5
2.1	Charakterystyka projektów	5
2.2	Harmonogramowanie	7
2.2.1	Klasyfikacja harmonogramów	8
2.3	Sposoby reprezentacji problemu harmonogramowania projektu	9
2.4	Problem optymalizacji harmonogramu projektu	12
2.4.1	Optymalizacja jednokryterialna	12
2.4.2	Optymalizacja wielokryterialna	12
2.4.3	Kryteria oceny	13
2.5	Klasyfikacja modeli harmonogramowania projektów	13
2.5.1	Modele harmonogramowania według zakresu podejmowanych decyzji	14
2.5.2	Modele harmonogramowania według rodzaju uwzględnionych ograniczeń	15
2.6	Metody harmonogramowania projektów	19
2.6.1	Metody dokładne	19
2.6.2	Heurystyki priorytetowe	22
2.6.3	Metaheurystyki	24
2.7	Podsumowanie	30
3	Ekonomiczne aspekty harmonogramowania projektów	31
3.1	Koszty realizacji projektów	31
3.2	Modele realizacji płatności	32
3.3	Płynność finansowa projektu	35
3.4	Metody oceny efektywności ekonomicznej projektów	35
3.4.1	Statyczne metody oceny	36
3.4.2	Dynamiczne metody oceny	36
3.5	Zastosowanie oceny efektywności ekonomicznej w harmonogramowaniu	39
3.6	Podsumowanie	40
4	Model harmonogramowania projektów z uwzględnieniem czynników ekonomicznych	41
4.1	Model harmonogramowania projektów	41
4.1.1	Założenia modelu	41
4.1.2	Opis strukturalny modelu	42
4.1.3	Sformułowanie ograniczeń	45
4.2	Sformułowanie kryteriów oceny	46
4.2.1	Kryteria organizacyjne	46
4.2.2	Kryteria ekonomiczne	46
4.3	Normalizacja problemu	49
4.4	Podsumowanie	50

5	Procedury optymalizacji efektów ekonomicznych realizacji harmonogramu	51
5.1	Kodowanie problemu harmonogramowania projektów	51
5.1.1	Reprezentacja problemu – kodowanie	52
5.2	Procedury dekodowania dla reprezentacji permutacyjnej	54
5.3	Techniki poszukiwania nowych rozwiązań – zależne od problemu	56
5.3.1	Techniki eksploatujące – techniki jedno-argumentowe	57
5.3.2	Techniki eksplorujące – techniki wielo-argumentowe	57
5.4	Symulowane wyżarzanie	58
5.5	Przeszukiwanie z tabu	60
5.6	Algorytmy genetyczne	61
5.6.1	Wprowadzenie	61
5.6.2	Funkcja celu	63
5.6.3	Skalowanie przystosowania	65
5.6.4	Selekcja osobników	65
5.7	Przeszukiwanie rozproszone	66
5.8	Algorytm uczenia populacji	67
6	Analiza wyników eksperymentów obliczeniowych	71
6.1	Założenia	71
6.1.1	Analiza dostępnych zestawów problemów testowych	71
6.1.2	Opis i analiza badanych problemów	73
6.1.3	Opis planu eksperymentów	74
6.1.4	Środowisko obliczeniowe	76
6.1.5	Metodyka analizy i oceny wyników badań	77
6.2	Analiza wpływu parametrów na efektywność wybranych metaheurystyk	78
6.2.1	Analiza wpływu parametrów na efektywność algorytmu SA	78
6.2.2	Analiza wpływu parametrów na efektywność algorytmu GA	83
6.2.3	Analiza wpływu parametrów na efektywność algorytmu TS	90
6.2.4	Analiza wpływu parametrów na efektywność algorytmu HA	93
6.3	Analiza porównawcza skuteczności wybranych metaheurystyk	97
6.3.1	Analiza porównawcza skuteczności względnej wybranych metaheurystyk	98
6.3.2	Analiza skuteczności względem rozwiązań optymalnych dla $\tilde{\Omega} = 10$	102
6.3.3	Analiza wpływu parametrów problemu ($\tilde{\Omega}$, $\bar{RS}^p$, $\bar{RS}^v$, NC) na skuteczność metaheurystyk	103
6.4	Analiza wybranych kryteriów optymalizacji dla problemów o $\tilde{\Omega}=10$	106
6.5	Podsumowanie i ocena badanych metod	110
7	Zakończenie i kierunki dalszych badań	113
A	Standaryzacja relacji	115
B	Opis formatu pso	117
C	Statystyki opisowe wyników badań eksperymentalnych	119
D	Tabele wyników analizy wariancji i testów <i>post-hoc</i>	155
	Oznaczenia	193
	Spis rysunków	199
	Spis tabel	201
	Spis algorytmów	203
	Bibliografia	205

Rozdział 1

Wstęp

1.1 Opis problemu

Niniejsza praca dotyczy problematyki związanej z budowaniem harmonogramów realizacji prac w organizacjach zarządzanych przez projekty. W ostatnich latach można zauważyć rosnące zainteresowanie tą formą wytwarzania i dostarczania zarówno dóbr inwestycyjnych, jak i konsumpcyjnych w rozmaitych gałęziach gospodarki. Jednym z istotnych zagadnień związanych z problematyką zarządzania projektami jest kwestia zbudowania i właściwej oceny jakości harmonogramu realizacji prac w ramach przedsięwzięcia lub portfela przedsięwzięć. Niezależnie od charakteru projektu, struktury jego finansowania, czy celów gospodarczych, zawsze jest on związany z poniesieniem w czasie określonych wydatków związanych z zaangażowaniem rozmaitych zasobów (w postaci: maszyn, środków transportu, materiałów, czy pracowników), zakupem różnego rodzaju energii czy usług, zarówno materialnych (m.in. transport, magazynowanie, utylizacja, wynajem maszyn, łączność) jak i niematerialnych (m.in. projektowanie, zarządzanie, pośrednictwo finansowe, doradztwo prawne) w celu osiągnięcia określonych wpływów w przyszłości. Wymienione cechy przedsięwzięcia przesądzą o potrzebie rozpatrywania go jako zjawiska ekonomicznego. Harmonogram stanowiąc jedno z najważniejszych narzędzi pozwalających na właściwe zarządzanie (w zakresie planowania, organizowania i kontroli) realizacją przedsięwzięcia, pozwala zwiększyć szanse uzyskania satysfakcjonującego efektu w zaplanowanych terminach i w ramach zatwierdzonych budżetów. Wobec istotnej roli harmonogramu, pojawia się pytanie będące główną motywacją przeprowadzenia opisanych w niniejszej pracy badań:

Czy możliwa jest optymalizacja harmonogramu projektu z uwzględnieniem czynników ekonomicznych oparta na nowoczesnych metaheurystykach?

Występują trzy zasadnicze przesłanki do przeprowadzenia niniejszych badań. Po pierwsze większość stosowanych komputerowych systemów wspomagających zarządzanie projektami nie oferuje możliwości optymalizacji harmonogramu umożliwiając jedynie jego zbudowanie i ocenę jakości (Herroelen, 2005, Katzel, 1999, Kolisch, 1999, Maroto i Tormos, 1994, Mellentien i Trautmann, 2001). Jednocześnie mankamentem większości istniejących metod optymalizacji możliwych do zastosowania w oprogramowaniu dla zarządzania projektami jest znaczny stopień uproszczenia modelu przedsięwzięcia i ukierunkowanie go na kryteria czasowe, których stosowanie dla oceny działalności gospodarczej jest niewystarczające. Często spotykaną praktyką jest ocena skutków ekonomicznych po zbudowaniu harmonogramu jako konsekwencji przyjętych rozwiązań, zamiast analizy efektów ekonomicznych już na etapie procesu decyzyjnego (Dixon, 2000, Kerzner, 2001, Maylor, 2003). Po trzecie można zaobserwować ciągle rosnące zainteresowanie i liczne sukcesy zarówno w zakresie badań naukowych jak i praktycznego zastosowania metaheurystyk m. in.: w modelowaniu ekonometrycznym (Koza, 1991), w obszarze finansów (Chen i in., 2007, Chen, 2002, Dacorogna i in., 1995, Kaboudan, 2006, Kim i Hanb, 2003, Mahfoud i Mani, 1996), w projektowaniu produktu (Balakrishnan i Jacob, 1996), w optymalizacji konstrukcji samolotu (Bramlette i Cusic, 1989), w optymalizacji procesu szlifowania (Baskar i in., 2004, Krishna i Rao, 2005, Mukherjee i Ray, 2008), w aktywnej redukcji hałasu (Makarewicz i Zawieska, 2003), w planowaniu sieci komórkowej (Raisanen i Whitaker, 2005), w zarządzaniu uprawą lasu (Bos, 1993, Ducheyne i in., 2004), w szacowaniu przepływu optycznego (Tagliasacchi, 2007).

1.2 Cel pracy i hipotezy badawcze

Celem niniejszej pracy jest opracowanie i badania procedur harmonogramowania projektów z ukierunkowaniem na kryteria ekonomiczne przy wykorzystaniu nowoczesnych metaheurystyk.

Kierując się sformułowanymi przesłankami i celem pracy główną tezę rozprawy określono następująco:

możliwe jest opracowanie lepszych, w sensie wybranych kryteriów ekonomicznych, harmonogramów realizacji przedsięwzięć poprzez zastosowanie nowoczesnych metaheurystyk.

Powyższe stwierdzenie pozwala na postawienie dalszych szczegółowych tez będących przedmiotem pracy:

1. Zastosowanie prostych metod heurystycznych (np. statycznych i dynamicznych priorytetów) harmonogramowania realizacji projektów nie musi prowadzić do wyników o zadowalającej jakości.
2. W literaturze przedmiotu brak jest metod harmonogramowania, które w sposób całościowy uwzględniają ekonomiczny charakter realizacji przedsięwzięcia.
3. Rozważanie wyłącznie kryteriów czasowych w przypadku harmonogramowania realizacji projektu jest niewystarczające – poprawa kryteriów czasowych nie musi warunkować poprawy wyników ekonomicznych.
4. Zastosowanie nowoczesnych metaheurystyk pozwala na konstruowanie efektywnych czasowo procedur harmonogramowania przedsięwzięć generujących dobre rozwiązania dla wybranych kryteriów ekonomicznych.

1.3 Metoda realizacji pracy

Dla weryfikacji prawdziwości postawionej tezy przeprowadzono kolejne etapy badawcze pracy:

- analiza literatury w zakresie modeli i metod harmonogramowania projektów,
- analiza zastosowań metod ewolucyjnych w planowaniu na podstawie literatury,
- budowa modelu harmonogramowania realizacji projektów z uwzględnieniem kryteriów ekonomicznych,
- opracowanie procedur optymalizacji harmonogramu opartych na wybranych metaheurystykach dla sformułowanego modelu (wraz z implementacją informatyczną),
- symulacyjne badanie efektywności opracowanych procedur dla wybranej grupy projektów o różnym stopniu złożoności oraz analiza wpływu parametrów projektu na skuteczność procedur,
- określenie wpływu parametrów analizowanych metaheurystyk na efektywność ich stosowania i narysowanie reguł doboru tychże parametrów,
- określenie zależności pomiędzy efektami techniczno-organizacyjnymi, a ekonomicznymi w przypadku harmonogramowania realizacji projektu,
- synteza wniosków z przeprowadzonych badań.

Pracę otwiera rozdział poświęcony definicjom oraz podstawowym pojęciom w zakresie zarządzania projektami i harmonogramowania. Kolejno przedstawiono klasyfikację problemów harmonogramowania projektów ze względu na stosowane kryteria oceny oraz zakres występujących ograniczeń. Następnie przedstawiono przegląd napotkanych w literaturze metod optymalizacji harmonogramów, w tym: algorytmów dokładnych, heurystyk priorytetowych oraz metaheurystyk. W kolejnym rozdziale przeanalizowano metody oceny jakości harmonogramu projektu, zarówno techniczno-organizacyjne jak i ekonomiczne. Przedstawiono wpływ poszczególnych zmiennych decyzyjnych w procesie harmonogramowania na poszczególne

kryteria czasowe i ekonomiczne. W następnym rozdziale sformułowano model harmonogramowania projektów uwzględniający ekonomiczny charakter projektu oraz pozwalający na możliwie dokładne opisanie zależności pomiędzy zmiennymi decyzyjnymi, a ich skutkami ekonomicznymi. Sformułowano ograniczenia zmiennych decyzyjnych oraz dynamiczne kryteria oceny efektywności ekonomicznej harmonogramu. Następny rozdział poświęcono analizie technik występujących w ramach metod dokładnych i heurystycznych, które mogą znaleźć zastosowanie w badanych procedurach z uwzględnieniem skonstruowanego uprzednio modelu. Przeanalizowano dostępne sposoby reprezentacji problemu, procedury budowy harmonogramów, techniki eksplorujące i eksploatujące oraz stosowane strategie kierowania poszukiwaniem w ramach algorytmu genetycznego, symulowanego wyżarzania, poszukiwania z ruchami zabronionymi, poszukiwania rozproszonego oraz algorytmu uczenia populacji. W następnym rozdziale przedstawiono opis założeń i wyników z przeprowadzonych eksperymentów obliczeniowych w możliwie szerokiej grupie problemów przy reprezentatywnym zestawie parametrów procedur. Pracę zamyka podsumowanie uzyskanych wyników oraz wskazanie kierunków prowadzenia dalszych badań.

Rozdział 2

Harmonogramowanie realizacji projektów

W rozdziale sprecyzowano definicje podstawowych pojęć stosowanych w harmonogramowaniu projektów, dokonano przeglądu spotykanych w literaturze modeli, metod i kryteriów oceny rozwiązań planistycznych.

2.1 Charakterystyka projektów

Zarządzanie przedsięwzięciami charakteryzuje się unikalnym zestawem pojęć wykorzystywanych przy ich opisie. Zgodnie z definicją British Standards przedstawioną w (Hougham, 2000) za (British Standards, 2000, 2002):

Projekt, przedsięwzięcie (ang. *Project*) – unikalny zbiór współzależnych czynności (zadań, operacji), wraz z określonym momentem rozpoczęcia i (lub) zakończenia, realizowany przez osobę prywatną lub organizację dla osiągnięcia przyjętych celów w ramach określonych zasobów.

Zgodnie z powyższą definicją każdy projekt posiada trzy zasadnicze elementy składowe: czynności, zasoby niezbędne do ich realizacji oraz relacje kolejnościowe (współzależności). Poniżej przedstawiono definicję tychże elementów.

Czynność to zadanie, operacja lub proces wymagające określonego czasu i (lub) zasobów dla zrealizowania. British Standards (British Standards, 2000)

Czynności opisane są poprzez następujące cechy (Dixon, 2000, Hougham, 2000, Kerzner, 2001, Maylor, 2003):

- określony czas trwania,
- połączone są współzależnościami (relacjami) z innymi czynnościami w projekcie,
- ich realizacja wymaga zaangażowania zasobów (ludzi, maszyn, materiałów),
- z ich realizacją związane są określone koszty,
- ich rozpoczęcie i zakończenie powinno być umiejscowione w określonej chwili czasu,
- powinny mieć przypisaną osobę lub organizację odpowiedzialną za ich wykonanie.

Zasoby to wszystko co jest niezbędne dla zrealizowania czynności i zwykle stanowi ograniczenie w realizacji projektu. Ograniczenia powodują ryzyko możliwości występowania barier w realizacji przedsięwzięcia, które Towarnicka (2003) klasyfikuje następująco:

- bariery ilościowej, gdy przedsiębiorstwo nie jest w stanie wykorzystać możliwości stwarzanych przez otoczenie społeczno-gospodarcze z powodu niewystarczających zasobów,
- bariery struktury zasobów, gdy struktura rodzajowa zasobów nie odpowiada potrzebom,

- bariery produktywności, gdy zasoby nie są efektywnie wykorzystane,
- bariera mobilności, gdy specyficzność zasobów utrudnia lub uniemożliwia inne od dotychczasowego ich wykorzystanie.

W procesie planowania realizacji przedsięwzięcia mogą wystąpić dowolne kombinacje barier i umożliwienie elastycznego opisanie ograniczeń w dostępności zasobów w układzie czasowym i ich uwzględnienie w procesie budowy harmonogramu pozwala na ograniczenie ryzyka ich wystąpienia.

Najpowszechniej stosowaną jest klasyfikacja oparta na kryterium dostępności, która dzieli zasoby na (Hougham, 2000, Kerzner, 2001, Kolisch i Padman, 2001, Maylor, 2003):

- z. **odnawialne** (ang. *renewable*) – dostępność tego rodzaju zasobu jest odnawiana w kolejnych okresach czasu (np. pracownicy, maszyny),
- z. **nieodnawialne** (ang. *non-renewable*) – zasób jest dostępny do chwili użycia dla realizacji zadania, po zużyciu przestaje być dostępny (np. materiały, kapitał),
- z. **podwójnie ograniczone** (ang. *doubly constrained*) – dostępna liczba jednostek zasobu jest ograniczona zarówno w okresie jak i horyzoncie planowania (np. dostępny kapitał dla całego projektu może dodatkowo okresowo być ograniczony do określonej kwoty). Węglarz (1981) przedstawia model harmonogramowania z zasobami podwójnie ograniczonymi o charakterze ciągłym. Talbot (1982) przedstawia możliwość zamiany zasobu podwójnie ograniczonego na dwa rozdzielne zasoby, z których jeden jest odnawialny, a drugi nieodnawialny.
- z. **częściowo odnawialne** (ang. *partially renewable*) – dostępność zasobu ograniczona jest dla określonych podzbiorów okresów czasu w ramach horyzontu planowania, w ramach tych podzbiorów zasób jest traktowany jak odnawialny. Dla różnych podzbiorów mogą być określone różne poziomy dostępności zasobów. Böttcher, Drexler, Kolisch i Salewski (1999) wprowadzając ten rodzaj zasobu, przekonują o jego przydatności dla modelowania zmianowego systemu pracy przy realizacji projektu. Schirmer i Drexler (2001) przedstawiają model wykorzystujący ten rodzaj zasobu oraz możliwości modelowania zasobów odnawialnych i nieodnawialnych za pomocą zasobu częściowo odnawialnego. Drexler, Nissen, Patterson i Salewski (2000) przedstawiają metodę generowania instancji problemów projektowych z zasobami częściowo odnawialnymi.

Relacje odwzorowują logiczną kolejność wykonywania czynności w ramach projektu (British Standards, 2000, 2002). Dla jednoznacznego określenia relacji konieczne jest podanie **poprzednika** (czyli czynności, która poprzez relację warunkuje rozpoczęcie lub zakończenie innej czynności), **następnika** (czynności, której możliwości realizacji są uwarunkowane poprzez relację) oraz rodzaju relacji. Kolisch i Padman (2001) wymieniają następujące rodzaje relacji:

- zakończenie-rozpoczęcie (ZR) – oznacza, że następnik może rozpocząć się nie wcześniej niż po zakończeniu poprzednika – jest to najpowszechniej stosowany w badaniach typ relacji,
- zakończenie-zakończenie (ZZ) – oznacza, że następnik może zakończyć się nie wcześniej niż po zakończeniu poprzednika,
- rozpoczęcie-rozpoczęcie (RR) – oznacza, że następnik może rozpocząć się nie wcześniej niż po rozpoczęciu poprzednika,
- rozpoczęcie-zakończenie (RZ) – oznacza, że następnik może zakończyć się nie wcześniej niż po rozpoczęciu poprzednika.

Dodatkowo w ramach relacji dopuszczalne jest stosowanie **opóźnienia** czasowego (ang. *lag*), nazywanego również **zwłoką** (Kolisch i Padman, 2001). Zwłoka może mieć wartość dodatnią wpływając na opóźnienie w czasie dostępności następnika, względnie wartość ujemną pozwalając na wcześniejszą dostępność czynności. Wielkość opóźnienia określana jest jako wartość graniczna (minimalna bądź maksymalna). Wielkość minimalna oznacza, że następnik może się rozpocząć (zakończyć) po upływie tejże zwłoki od zakończenia (rozpoczęcia) poprzednika. Wielkość maksymalna oznacza, że następnik musi się rozpocząć

(zakończyć) nie później, niż po upływie zwłoki od momentu zakończenia (rozpoczęcia) poprzednika. Elmaghraby i Kamburowski (1992) określają tak sformułowany model mianem **ogólnego modelu relacji** (ang. GPR – *Generalized Precedence Relations*). Bartusch, Möhring i Radermacher (1988) przedstawiają metodę standaryzacji relacji, czyli sposób przekształcenia wszystkich typów relacji w jeden (dowolny spośród nich) za pomocą określenia granicznych wartości opóźnień.

Bardziej złożoną strukturą wyróżnianą w literaturze jest program. Zgodnie z definicją Association for Project Management (APM) (Dixon, 2000):

Program stanowi przedsięwzięcie obejmujące zbiór projektów i/lub czynności funkcjonalnych realizowanych dla osiągnięcia wspólnego celu.

Istotną cechą programu jest realizacja projektów składowych w ramach wspólnej (lub częściowo wspólnej) puli zasobów. Ze względu na strukturę i zależności w środowisku jednoczesnej realizacji wielu projektów Ireland (2002) wyróżnia dwa zasadnicze podejścia:

- **wielo-projektowe** (ang. *Multi-Project*) – zarządzanie oparte jest o wiele równolegle realizowanych projektów pomiędzy którymi nie ma bezpośrednich relacji kolejnościowych, wzajemne uzależnienie projektów wynika z wykorzystywania wspólnych zasobów,
- **wielko-projektowe** (ang. *Mega-Project*) – pomiędzy projektami, lub ich czynnościami zachodzą związki kolejnościowe, a ponadto korzystają one ze współdzielonych zasobów tworząc w całości superprojekt.

Hans, Herroelen, Leus i Wullink (2007) wyraźnie rozróżniają powyższe dwa podejścia do środowiska wielu projektów. Autorzy traktują podejście wielko-projektowe jak synonim programu, wskazując na wspólny cel jako istotną cechę wyróżniającą (np. projekt wysłania człowieka na księżyc), w odróżnieniu od podejścia wielo-projektowego, gdzie w sensie operacyjnym każdy projekt ma własny cel (np. planowanie remontów statków). Podobnie Wirkus (2006) środowisko wielko-projektowe określa mianem programu, natomiast dla opisanego środowiska wielo-projektowego posługuje się terminem **teczki** lub **portfela projektów**. Dodatkowo poza licznymi różnicami pomiędzy powyższymi formami Wirkus wskazuje na możliwość występowania obydwóch form jednocześnie i wzajemnego się ich przenikania¹. Brilman (2002) opisuje zarządzanie wielo-projektowe w perspektywie przedsiębiorstw realizujących produkcję w ramach projektów. Stwierdza, że:

Ponad 25% działalności gospodarczej nadaje się do zarządzania przez projekty. Dotyczy to głównie takich dziedzin, jak inżynieria, sektor prac publicznych, przemysł lotniczy i obronny, budowa statków, doradztwo organizacyjne itp. (Brilman, 2002, s. 318)

Wymienione przykłady dziedzin stosowania świadczą wymownie o atrakcyjności i perspektywach aplikacyjnych metod zarządzania w środowisku realizacji wielu projektów jednocześnie.

2.2 Harmonogramowanie

Harmonogramowanie polega na określaniu terminów rozpoczęcia i zakończenia realizacji czynności. Z jednej strony jest to więc bardzo prosta operacja, jednak należy zauważyć, że przypisanie tych terminów do czynności wiąże się z licznymi wymaganiami (w przypadku uwzględniania w harmonogramie ograniczeń) lub konsekwencjami (w przypadku zamiany ograniczeń na kierunki optymalizacji) w postaci: zapotrzebowania na wszelkiego rodzaju zasoby, możliwości spełnienia zależności kolejnościowych, ograniczeń względnych i bezwzględnych oraz spełnieniem celów projektu wyrażonych w wartościach kryterium optymalizacji. Harmonogram stanowi podstawę do zarządzania operacyjnego realizacją projektu i kontroli postępu prac. Z punktu widzenia niniejszej pracy istotne jest przedstawienie rodzajów harmonogramów i wiążących się z nimi możliwości odnalezienia rozwiązania optymalnego, gdyż to pozwoli właściwie określić przestrzeń rozwiązań.

¹Przykładem, który przedstawiono jest realizacja remontu generalnego zabytkowej hali targowej w Gdańsku w latach 2001–2005 (Wirkus, 2006, s. 67).

2.2.1 Klasyfikacja harmonogramów

Klasyfikacja harmonogramów realizacji projektów oparta jest na podziale stosowanym dla ogólnych problemów produkcji (ang. *job-shop*), który przedstawiają m.in. Conway, Maxwell i Miller (1967), Baker (1974), Bierwirth i Mattfeld (1999), Pawlak (1999). Jednolitą i sformalizowaną klasyfikację dla problemów typu projektowego przedstawiają Sprecher, Kolisch i Drexel (1995). W zależności od zastosowanej procedury budowy harmonogramu (wykorzystującej uszeregowanie zadań) można uzyskać harmonogramy o zróżnicowanych właściwościach:


- h. **niedopuszczalne** (ang. *infeasible*) – zbiór harmonogramów nie spełniający nałożonych ograniczeń kolejnościowych lub dostępności zasobów,
- h. **dopuszczalne** (ang. *feasible*) – zbiór harmonogramów spełniających wszystkie nałożone ograniczenia zarówno dostępności zasobów, jak i kolejności realizacji zadań,
- h. **półaktywne**² (ang. *semiactive*) zwane również **półwartytmi** (Janiak, 1999) – podzbiór zbioru harmonogramów dopuszczalnych. Zawiera harmonogramy, w których operacje są umieszczane w najwcześniejszych możliwych terminach. Harmonogram dopuszczalny może być przekształcony w pseudoaktywny poprzez przesunięcie lokalne operacji w lewo. Wiest (1964) określa przekształcenie to (ang. *local left shift*), jako zmianę terminu rozpoczęcia czynności poprzez serię kolejnych przesunięć o jedną jednostkę czasu bez naruszania ograniczeń.
- h. **aktywne** (ang. *active*) – podzbiór zbioru harmonogramów pseudoaktywnych. Zawiera harmonogramy, w których czynności są umieszczone tak, że nie ma możliwości ich wcześniejszego rozpoczęcia bez naruszenia ograniczeń kolejnościowych lub opóźnienia innej czynności. Wiest (1964) określa globalne przesunięcie w lewo jako przesunięcie czynności do najwcześniejszego możliwego terminu wykonania, które nie jest osiągalne na drodze przesunięcia lokalnego.
- h. **bez opóźnień** (ang. *nondelay*) – stanowią podzbiór zbioru harmonogramów aktywnych. Operacje umieszczone w harmonogramie są wybierane ze zbioru operacji możliwych do zaplanowania w danej chwili tzn. tych dla których operacje poprzedzające zostały zakończone i zasoby potrzebne do realizacji są dostępne. W harmonogramie bez opóźnień zasób nie pozostaje wolny jeżeli może być wykorzystany do jakiegokolwiek operacji.

W przypadku problemów harmonogramowania opartych na regularnych kryteriach oceny (patrz p. 2.4) najkorzystniejsze warunki przeszukiwania – z uwagi na najmniejszy rozmiar – daje przestrzeń harmonogramów bez opóźnień. Jednak nie daje ona gwarancji odnalezienia rozwiązania optymalnego. Co najmniej jeden harmonogram optymalny jest aktywny, natomiast żaden ze zbioru harmonogramów optymalnych nie musi być harmonogramem bez opóźnień (Mattfeld, 1995). Przestrzeń harmonogramów bez opóźnień daje jednak lepsze średnie wyniki, pozwalając tym samym na uzyskanie dobrych wyników przy ograniczonym czasie obliczeń (Storer i in., 1992). Storer, Wu i Vaccari (1992) proponują algorytm tworzący harmonogram hybrydowy dla potrzeb ogólnych problemów harmonogramowania, który pozwala na elastyczne zawężenie przeszukiwanej przestrzeni harmonogramów aktywnych (w skrajnym przypadku do zbioru harmonogramów bez opóźnień).

Neumann, Nübel i Schwindt (2000) rozszerzają klasyfikację harmonogramów wykonalnych dostosowując ją do wymagań problemów ze względnymi i bezwzględnymi ograniczeniami czasowymi. Zaproponowany podział uwzględnia również potrzeby optymalizacji ze względu na nieregularne kryteria oceny harmonogramu. W efekcie autorzy wyróżniają osiem rodzajów harmonogramów³: kwaziaktywne (ang. *quasiactive*), kwazistabilne (ang. *quasistable*), pseudoaktywne (ang. *pseudoactive*), pseudostabilne (ang. *pseudostable*), półaktywne (ang. *semiactive*), półstabilne (ang. *semistable*), aktywne (ang. *active*), stabilne (ang. *stable*). Na nazwę każdej klasy składają się dwa człony. Termin *aktywny* odnosi się do harmonogramów stanowiących minimalny punkt w przestrzeni rozwiązań, natomiast *stabilny* odnosi się do tych, które stanowią

² w publikacjach polskich autorzy stosują dla terminu *semiactive* tłumaczenie *pseudoaktywny*, które jednak nie będzie zgodne z najnowszą klasyfikacją, w której Neumann, Nübel i Schwindt (2000) rozróżniają dwie odrębnie klasy *semiactive* oraz *pseudoactive*

³ w literaturze krajowej brak jednolitych terminów określających poszczególne klasy. Przedstawione terminy stanowią jedynie próbę przetłumaczenia oryginalnych odpowiedników angielskich, które są powszechnie stosowane.



Rys. 2.1: Przykładowa sieć typu AON dla projektu z dwoma zasobami

punkty ekstremalne. Kolejne zawężenia w ramach klas odnoszą się do poziomu lokalności minimów (ekstremów). Harmonogramy aktywny i stabilny odnoszą się do punktów minimalnych (ekstremalnych) w całej przestrzeni harmonogramów wykonalnych, natomiast półaktywny (półstabilny) do minimów (ekstremów) lokalnych. Klasy quasi- i pseudo- odnoszą się do harmonogramów, które mogą być uzyskane na drodze globalnego (lokalnego) przesunięcia czynności z zachowaniem kolejności ich wykonywania.

2.3 Sposoby reprezentacji problemu harmonogramowania projektu


Powszechnie stosowane jest reprezentowanie problemu harmonogramowania projektów w formie sieci (grafów). Elmaghraby (1970a,b) przedstawia ogólny przegląd sieci i ich zastosowania m.in. w modelowaniu projektów. Dla potrzeb problemów harmonogramowania projektu stosowane są dwa rodzaje reprezentacji: czynność na węźle (ang. AON – *Activity-On-Node*) oraz czynność na łuku (ang. AOA – *Activity-On-Arc*). Sysło, Deo i Kowalik (1995) przyjmują nazewnictwo związane z definicją wierzchołków grafu – sieć typu AON nazywają **siecią czynności**, natomiast sieć typu AOA nazywają **siecią zdarzeń**. Do prezentacji rozwiązania problemu harmonogramowania projektów najczęściej stosowaną formą jest wykres Gantt’a.

Sieć AON stanowi acykliczny graf skierowany $G^{AON} = (W, K)$, w którym W oznacza zbiór wierzchołków (węzłów) odpowiadających czynnościom, a K oznacza zbiór łuków, które odpowiadają relacjom kolejnościowym w modelu. Zwykle do zbioru W dołączane są dwie czynności odpowiadające rozpoczęciu i zakończeniu projektu (źródło i odpływ). Przykład sieci AON dla problemu RCPS z dwoma zasobami przedstawiono na rys. 2.1.

Sieć AOA stanowi acykliczny graf skierowany $G^{AOA} = (W, K)$, w którym łuki odpowiadają czynnościom natomiast węzły oznaczają zdarzenia (odpowiadają momentom w których rozpoczynają się i kończą czynności). Odwzorowanie problemu RCPS za pomocą sieci zdarzeń przedstawiono na rys. 2.2. W sieci AOA występują **czynności pozorne**, czyli takie, które odwzorowują zależności kolejnościowe pomiędzy rzeczywistymi czynnościami. Czynności pozorne nie zużywają czasu, ani zasobów. Na rys. 2.2 czynność pozorna oznaczona została linią przerywaną.

W przypadku problemów harmonogramowania zorientowanych na optymalizację kryteriów czasowych najpowszechniej stosowana jest reprezentacja w postaci sieci AON. Węzły sieci oznaczają wówczas czynności, natomiast łuki oznaczają zależności kolejnościowe pomiędzy czynnościami. Wagi przypisane do łuków oznaczają opóźnienie czasowe w relacji pomiędzy czynnościami. Reprezentacja AON stosowana jest zwyczajowo w komercyjnym oprogramowaniu m. in.: Microsoft Project, Welcom Open Plan, Primavera. Reprezentacja w postaci sieci AOA stosowana jest w metodzie CPM⁴ (ang. *Critical Path Method*).

⁴Jedną z metod stosowanych w zarządzaniu projektami. Zaprojektowana została w roku 1958 w amerykańskiej firmie chemicznej DuPont, w celu usprawnienia procesów produkcji. Pozwala na graficzną prezentację kolejnych czynności wykonywanych w ramach projektu, z zaznaczeniem szacowanego czasu trwania tych czynności, oraz z zachowaniem ich sekwencji. Obszerne omówienie metody można znaleźć m. in. w (Trocki i in., 2003, Zawadzka, 1997).



Rys. 2.2: Przykładowa sieć typu AOA dla projektu z rys. 2.1 z pominięciem informacji o zasobach


W metodzie PERT⁵ (ang. *Project Evaluation and Review Technique*) stosowane są zarówno sieci AOA, jak i AON. Sposób reprezentacji ma charakter zwyczajowy i nie wpływa na sformułowanie problemu. Wydaje się, że reprezentacja AON jest bardziej czytelna w przypadku modelowania złożonych projektów.

Uwzględnienie przepływów pieniężnych w konstrukcji sieci wymaga poszerzenia definicji węzłów, bądź łuków o kolejne parametry. W przypadku sieci AON przyjmowane są założenia, że wydatki związane z realizacją czynności ponoszone są w całości w momencie jej rozpoczęcia, natomiast przychody są uzyskiwane w chwili zakończenia realizacji czynności. W takim przypadku struktura sieci pozostaje bez zmian. Przykład sieci AON z przepływami pieniężnymi przedstawiono na rys. 2.3.


W przypadku sieci AOA przepływy powiązane są ze zdarzeniami reprezentowanymi przez węzły. Russell (1970) poszerza definicję węzła o parametr odpowiadający wielkości przepływu pieniężnego w chwili wystąpienia zdarzenia dla problemu bez ograniczonych zasobów. Russell (1986) przedstawia sieć czynności z ograniczonymi zasobami i przepływami pieniężnymi. Przykład sieci AOA z przepływami przedstawiono na rys. 2.4. Kolisch i Padman (2001) zauważają następujące niejednoznaczności w tak zdefiniowanej sieci: (1) nie wiadomo z którą z czynności związany jest przepływ, (2) brak informacji czy przepływ związany jest z zakończeniem czynności wchodzącej do węzła, czy z rozpoczęciem czynności z węzła wychodzącej, (3) jeżeli jest to kwota netto stanowiąca różnicę przychodów czynności wchodzących i wydatków czynności wychodzących to powoduje to utratę informacji o wpływach i wydatkach. Wszystko to powoduje, że tak zdefiniowana sieć pozostawia niemożność powiązania wydatków i wpływów z realizacją czynności. Dla rozwiązania powyższych problemów Padman, Smith-Daniels i Smith-Daniels (1997) proponują wstawienie bezpośrednio przed czynnością i po niej dodatkowych czynności pozornych. Po zmianie przepływy zdefiniowane w węźle przed będą określały wydatki związane z rozpoczęciem czynności, natomiast w węźle za czynnością określone zostaną przychody z tytułu jej zakończenia. Przykład tak zdefiniowanej sieci AOA przedstawia rys. 2.5.

Kolejne rozszerzenie sieci AON konieczne jest dla zdefiniowania względnych ograniczeń czasowych. Ograniczenie minimalnego opóźnienia wprowadzone jest poprzez oznaczenie wagi łuku pomiędzy czynnościami, które są połączone relacją, natomiast ograniczenie maksymalnego opóźnienia wprowadzane jest poprzez łuk skierowany przeciwnie o wadze odpowiadającej wartości przeciwnej temu opóźnieniu. Przykład sieci tego typu przedstawiono na rys. 2.6. Łuk od czynności 1 do 3 definiuje minimalne opóźnienie o wielkości 2, natomiast łuk od czynności 3 do 1 definiuje maksymalne opóźnienie o wielkości 4. Przykładem ścisłego ograniczenia są czynności 2 i 3, zarówno minimalne jak i maksymalne opóźnienie wynosi 0, co oznacza że muszą one być wykonane bezpośrednio po sobie. Uwzględnienie narzuconego terminu realizacji projektu o wielkości 9 możliwe jest poprzez zdefiniowanie łuku od Z do R.


⁵Jedna z metod planowania i kontroli projektu, wykorzystująca programowanie sieciowe. Została opracowana przez Departament Obrony Stanów Zjednoczonych w latach 1956–1957, na potrzeby marynarki wojennej USA podczas realizacji projektu budowy rakiet balistycznych Polaris. Szczegółowy opis wraz z rozszerzeniami metody można znaleźć m. in. w (Trocki i in., 2003, Zawadzka, 1997).




Rys. 2.3: Przykładowa sieć typu AON z przepływami pieniężnymi



Rys. 2.4: Przykładowa sieć typu AOA z uwzględnieniem przepływów pieniężnych (na podstawie sieci AON z rys. 2.3)



Rys. 2.5: Przykładowa sieć typu AOA z uwzględnieniem przepływów pieniężnych powiązanych z realizacją czynności (odpowiada sieci AON z rys. 2.3)



Rys. 2.6: Przykładowa sieć typu AON ze względnymi ograniczeniami czasowymi

2.4 Problem optymalizacji harmonogramu projektu

Konstrukcja modelu harmonogramowania, jego struktura i dane uzależnione są od celu działań optymalizacyjnych wyznaczanych i określanych ilościowo poprzez sformułowanie kryteriów oceny. Kluczowym utrudnieniem w zakresie optymalizacji harmonogramów projektu są ograniczenia warunkujące możliwości zbudowania wykonalnego harmonogramu. Ograniczenia wynikają z trzech czynników: (1) czasu, (2) zasobów oraz (3) kapitału. Te trzy czynniki wyznaczają również kierunki optymalizacji i stosowane kryteria oceny.

2.4.1 Optymalizacja jednokryterialna

Najpowszechniej przyjmowanym kierunkiem jest optymalizacja jednokryterialna dla wybranego czynnika pozostałe dwa lub jeden z nich przyjmowane są jako ograniczenie lub pomijane – pozwala to wyodrębnić 8 klas modeli (patrz rys. 2.7). W przypadku harmonogramowania realizacji projektu najpowszechniej stosowane są następujące podejścia: (1) przyjęcie ograniczenia czasowego realizacji projektu i optymalizowanie poziomu zapotrzebowania na nieograniczone zasoby produkcyjne lub przepływów pieniężnych, (2) przyjęcie ograniczonych zasobów i optymalizacja czasu realizacji projektu bądź przepływów pieniężnych lub (3) przyjęcie ograniczenia czasu i (lub) zasobów i optymalizowanie przepływów pieniężnych.

2.4.2 Optymalizacja wielokryterialna

Niewiele opracowań z zakresu harmonogramowania projektu podejmuje problem optymalizacji wielokryterialnej. Przejście od analizy jednokryterialnej do wielokryterialnej realizowane jest zwykle poprzez zamianę ograniczeń (np. zasobowych) na kierunki optymalizacji (np. równomierność obciążenia zasobów). Viana i de Sousa (2000) zajmują się analizą wielokryterialną charakterystyk czasowych. Lova, Maroto i Tormos (2000) harmonogramują realizację wielu projektów jednocześnie kierując się: (1) płynnością realizacji projektu – minimalizacją rozpiętości czasowej realizacji projektu (dla oceny przyjmują nieciągłość projektu *project splitting*), (2) minimalizacją zapasów w toku (ang. *in-process inventory*) określoną jako opóźnienie realizacji czynności spowodowane niedostępnością zasobów, (3) równomiernością obciążenia zasobów odnawialnych oraz (4) minimalizacją niewykorzystywania zasobów. Dwa pierwsze kryteria wyznaczają kierunek optymalizacji charakterystyk czasowych, kolejne dwa optymalizacji charakterystyk zasobowych. Leu i Yang (1999) pomijają wszelkie ograniczenia i przyjmują dwa kierunki optymalizacji: (1) minimalizację czasu realizacji i (2) minimalizację kosztów. Konflikt wynika z możliwości skracania czasu realizacji projektu za cenę konieczności poniesienia dodatkowych wydatków. Hapke, Jaskiewicz i Słowiński (1998) optymalizują harmonogram realizacji projektu kierując się: (1) minimalizacją czasu trwania, (2) równomiernością obciążenia zasobów oraz (3) minimalizacją kosztów realizacji projektu.

Podobne podejście prezentuje Jaskiewicz (2001) stosując praktycznie w warunkach harmonogramowania projektu rolniczego opracowaną przez siebie metaheurystykę dla rozwiązywania kombinatorycznych problemów optymalizacji wielokryterialnej.

2.4.3 Kryteria oceny

Z kierunkami optymalizacji wiążą się ściśle wykorzystywane kryteria oceny: czasowe, zasobowe i ekonomiczne. Najpowszechniej w literaturze podejmowane są badania stosujące kryteria czasowe. O ile w przypadku problemów harmonogramowania produkcji (jedno- i wielo-stanowiskowych) zbiór kryteriów czasowych jest bardzo rozwinięty – Janiak (1999) wymienia: czas zakończenia wszystkich prac, średni czas przepływu zlecenia, opóźnienie realizacji, wyprzedzenie realizacji, nieterminowość realizacji – o tyle w przypadku harmonogramowania realizacji projektu powszechnie stosowanym kryterium czasowym jest termin zakończenia realizacji (m.in. Bianco, Dell’Olmo i Speranza (1998), Boctor (1993, 1996a,b), Böttcher, Drexl, Kolisch i Salewski (1999), Bowman (1959), Brucker, Knust, Schoo i Thiele (1998), Chelaka, Abeyasinghe, Greenwood i Johansen (2001), Cooper (1976), Demeulemeester i Herroelen (1992, 1996), Elsayed (1982), Kolisch (1996b), Patterson i Huber (1974)). Kurtulus i Davis (1982) dla środowiska wielo-projektowego stosują jako miarę opóźnienie realizacji projektu względem realizacji projektu bez ograniczonych zasobów (co w efekcie nie różni się od przyjęcia kryterium czasu zakończenia).

Wartość zaktualizowana netto (ang. NPV – *Net Present Value*) stanowi najpowszechniej stosowane kryterium ekonomiczne (m.in. Abbasi i Arabiat (2001), Doersch i Patterson (1977), Neumann i Zimmermann (2000), Sunde i Lichtenberg (1995), Ulusoy i Özdamar (1995), Ulusoy, Sivrikaya-Şerifoğlu i Şahin (2001)). W badaniach brak jest kryteriów ekonomicznych uwzględniających płynność finansową przedsięwzięcia. Kwestia poziomu zaangażowania środków pieniężnych traktowana jest co najwyżej jako ograniczenie w budowie harmonogramu (m.in. Smith-Daniels, Padman i Smith-Daniels (1996), Talbot (1982), Węglarz (1981)). Innym stosowanym kryterium jest koszt realizacji projektu. Stosowanie kryterium kosztu ograniczone jest do problemów z wyborem sposobu realizacji czynności (patrz p. 2.5) lub problemów z karą za opóźnienie realizacji (Ahn i Erenguc, 1998). Bailey, Alfares i Lin (1995) odnoszą kryterium kosztu do optymalizacji przydziału pracowników.

W przypadku optymalizacji rozdziału zasobów przy ograniczeniach czasowych przyjmowane są kryteria oceny związane z zaangażowaniem zasobów. Pawlak (1999) wymienia trzy kryteria: (1) średnie kwadratowe chwilowe odchylenie zapotrzebowania na zasoby względem średniego zapotrzebowania dziennego, (2) maksymalne absolutne chwilowe odchylenie zapotrzebowania na zasoby względem średniego zapotrzebowania dziennego oraz (3) maksymalne zapotrzebowanie dzienne. Nudtasomboon i Randhawa (1997) wymieniają ogólnie dwa kierunki optymalizacji: (1) minimalizacja odchylenia od założonego poziomu wykorzystania zasobu lub (2) minimalizacja zmienności zapotrzebowania na zasób w założonym okresie czasu.

Oryginalne podejście do oceny harmonogramu prezentują Icmeli-Tukel i Rom (1997). Wprowadzają oni nowy kierunek optymalizacji oparty na ocenie jakości projektu. Jakość jest tu postrzegana w perspektywie poprawiania prac już wykonanych i wiążących się z tym kosztów i dodatkowego przesunięcia terminu zakończenia projektu. Inny kierunek badań podejmują Dodin i Elimam (2001) łącząc optymalizację harmonogramu projektu z optymalizacją zaopatrzenia materiałowego.

2.5 Klasyfikacja modeli harmonogramowania projektów

Z powodu dużego zróżnicowania problemów harmonogramowania projektów brak jest jednoznacznej klasyfikacji stosowanych modeli. Autorzy kierując się różnymi kryteriami proponują wycinkowe klasyfikacje dla ograniczonego zakresu modeli. Wynika to ze złożoności i ogromnej różnorodności problemów harmonogramowania projektu.

Ogólny przegląd deterministycznych modeli harmonogramowania projektu przedstawiają Icmeli, Erenguc i Zappe (1993). Herroelen, Reyck i Demeulemeester (1998) wzbogacają swój przegląd zagadnień o formalizm matematyczny. Brucker, Drexl, Möhring, Neumann i Pesch (1999) przedstawiają najbardziej

kompleksową klasyfikację problemów harmonogramowania projektów wraz z notacją odpowiadającą wymogom powszechnie stosowanej trójpolowej notacji, którą przedstawia Graham, Lawler, Lenstra i Kan (1979). Krytyczną analizę ostatniej wymienionej klasyfikacji przedstawili Herroelen, Demeulemeester i Reyck (2001) wskazując na nadmierne skomplikowanie, brak elastyczności, uproszczone ograniczenia czasowe i niemożność opisanego w nim niektórych modeli zwłaszcza stochastycznych. Kolisch i Padman (2001) przedstawiają wprowadzenie w zagadnienia deterministycznego harmonogramowania projektu wraz z prezentacją modeli. Herroelen, Dommelen i Demeulemeester (1997) przedstawiają charakterystykę modeli z uwzględnieniem dyskontowanych przepływów pieniężnych. Obszarem stochastycznych modeli harmonogramowania zajmują się: de Vonder, Ballestin, Demeulemeester i Herroelen (2007), Neumann (1984), Stork (2001).

W niniejszej pracy przyjęto klasyfikację opartą na rodzajach ograniczeń i kierunkach optymalizacji. Podejście to wydaje się najbardziej zasadne z punktu widzenia celu harmonogramowania i kluczowej roli ograniczeń w procesie planowania. Mając na uwadze rodzaj ograniczeń i kierunki optymalizacji w obszarze harmonogramowania projektów można wyróżnić podstawowe klasy problemów (rys. 2.7):


- bez ograniczeń – z optymalizacją czasu realizacji, bądź przepływów pieniężnych,
- z ograniczeniami czasowymi – z optymalizacją rozdziału zasobów, bądź przepływów pieniężnych,
- z ograniczonymi zasobami (różnych rodzajów) – z optymalizacją charakterystyk czasowych, bądź pieniężnych,
- z ograniczonym kapitałem – z maksymalizacją NPV,
- z wieloma ograniczeniami – kombinacje powyższych modeli.

Dodatkowo modele są zróżnicowane m.in. poprzez: rodzaje relacji, rodzaje zasobów, dostępność zasobów (stała/zmienna), sposób określenia zapotrzebowania na zasób (stałe/zmienne), rugowanie czynności. Często przyjmuje się, że modele podwójnie (potrójnie) ograniczone stanowią rozszerzenie modelu *RCPS*.

2.5.1 Modele harmonogramowania według zakresu podejmowanych decyzji

Istotnym elementem wyróżniającym modele harmonogramowania projektu jest zakres decyzji, których podjęcia wymaga rozwiązanie postawionego problemu. Wśród modeli harmonogramowania projektu można wyróżnić **ze względu na obszar decyzyjny**:

- modele w których zmienną decyzyjną jest **wyłącznie harmonogram realizacji czynności** – niezależnie od kierunku optymalizacji, kryterium oceny zależne jest jedynie od terminu rozpoczęcia i zakończenia czynności, rozwiązaniem problemu są te właśnie terminy. Badania w tym obszarze prowadzą m.in.: Abbasi i Arabiat (2001), Boctor (1990, 1993, 1996b), Böttcher, Drexler, Kolisch i Salewski (1999), Brucker, Knust, Schoo i Thiele (1998), Cesta, Oddi i Smith (2002), Cooper (1976), Davis i Heidorn (1971), Davis i Patterson (1975), Demeulemeester i Herroelen (1992, 1996, 1997), DePuy i Whitehouse (2001), Russell (1970), Schwindt i Zimmermann (2001), Vanhoucke, Demeulemeester i Herroelen (2002b).
 - modele w których decyzje dotyczą **zarówno harmonogramu, jak i sposobu wykonania czynności** – modele ze zmiennym zapotrzebowaniem na zasoby (i/lub kapitał) określonym w formie zależności (ang. *trade-off*). Zależność ta może mieć charakter ciągły – w takim przypadku zwykle podawane są dwie wartości graniczne: czas normalny i krytyczny (ang. *crash time*) oraz zależność wiążąca czas trwania z liczbą zaangażowanych jednostek zasobu (kosztem). Natomiast zależności dyskretne modelowane są w formie skończonego zbioru możliwych kombinacji (ang. *modes*) zapotrzebowania na zasoby (i/lub kapitał) oraz związanego z nimi czasu trwania czynności. Rozwiązanie tak sformułowanego problemu wymaga podania zarówno czasów uruchomienia czynności, jak i wybranego sposobu ich wykonania.
- Arisawa i Elmaghraby (1972), Fulkerson (1961) oraz Sunde i Lichtenberg (1995) stosują liniowe zależności czas/koszt, Lamberson i Hocking (1970) modelują zależności wypukłe, Berman (1964)



Rys. 2.7: Ograniczenia w modelach harmonogramowania projektów

wklęsłe, Deckro, Hebert, Verdini, Grimsrud i Venkateshwar (1995) zależności kwadratowe, natomiast Icmeli i Erenguc (1996b), Vanhoucke, Demeulemeester i Herroelen (2002a) dyskretne. Achuthan i Hardjawidjaja (2001) rozróżniają koszt stały niezależny od czasu realizacji czynności oraz koszt zmienny zależny w sposób ciągły od tegoż czasu. Ahn i Erenguc (1998) definiują model określony mianem *multiple crashable modes* łączący cechy dyskretne i ciągłe. Dla czynności określają kilka możliwych sposobów wykonania z wykorzystaniem różnych zasobów, a dodatkowo czas realizacji w ramach wybranego sposobu wykonania może być skracany w sposób ciągły do wartości krytycznej.

Demeulemeester, de Reyck i Herroelen (2000) modelują czas w formie dyskretnej nierosnącej funkcji liczby jednostek odnawialnego zasobu. Problem wyboru sposobu wykonania po kątem zaangażowanych zasobów badają m.in. Bianco, Dell’Olmo i Speranza (1998), Bector (1996a), Hartmann (2001), Hartmann i Drexel (1997), Heilmann (2001), Józefowska, Mika, Różycki, Waligóra i Węglarz (2001), Kolisch i Drexel (1997), Mori i Tseng (1997), Nudtasomboon i Randhawa (1997), Ranjbar i Kianfar (2007), Reddy, Kumanan i Chetty (2001), Reyck i Herroelen (1999), Sprecher i Drexel (1996a,b, 1998), Sung i Lim (1997), Talbot (1982), Ulusoy, Sivrikaya-Şerifoğlu i Şahin (2001). Salewski, Schirmer i Drexel (1996a, 1997) dokonują wyboru sposobu realizacji dla wyodrębnionych grup czynności zamiast niezależnego wyboru dla każdej czynności odrębnie. W pracy (Salewski i in., 1996b) przedstawiają możliwość zastosowania grup czynności o wspólnym sposobie wykonania do modelowania pracy audytorów. Sprecher, Hartmann i Drexel (1994) poza dyskretną zależnością czas/zasób dodatkowo wprowadzają również dyskretną zależność zasób/zasób (możliwość wykonania czynności z zaangażowaniem innego zasobu).

- modele, w których decyzje dotyczą określenia **harmonogramu projektu oraz terminów realizacji płatności**. W konstrukcji dotychczas przedstawianych modeli przyjmowano założenie, że wielkość i termin wystąpienia przepływów pieniężnych jest znany. W modelu harmonogramowania płatności (ang. PPS – *Project Payment Scheduling*) przyjmuje się, że: (1) wydatki związane z realizacją projektu są znane, (2) wydatki realizującego występują częściej niż przychody, (3) wysokość płatności zależna jest od poniesionych kosztów, (4) całkowita kwota płatności jest stała i znana. Celem modelu jest określenie harmonogramu realizacji projektu oraz wielkości i terminu wystąpienia płatności dla uzyskania maksymalnego NPV.

Dayanand i Padman (2001b) przedstawiają problem PPS z punktu widzenia realizującego projekt, natomiast w pracy (Dayanand i Padman, 2001a) z punktu widzenia klienta. Ulusoy i Cebelli (2000) szukają rozwiązania zadowalającego zarówno klienta, jak i realizującego. Ulusoy, Sivrikaya-Şerifoğlu i Şahin (2001) analizują cztery modele realizacji płatności: (1) całość po zakończeniu realizacji, (2) częściowo po zakończeniu wybranych czynności, (3) płatności w stałych i znanych z góry interwałach czasowych, (4) w interwałach czasowych z nie określoną liczbą płatności.

2.5.2 Modele harmonogramowania według rodzaju uwzględnionych ograniczeń

W dalszej części rozdziału przedstawiono charakterystykę modeli harmonogramowania według kryterium rodzaju ograniczeń wraz z przykładami prowadzonych badań.

Kryterium oceny	UPS	TCPS	RCPS	CCPS	TRCPS	TCCPS	RCCPS	TRCCPS
– czas	✓	✓	✓	✓	✓	✓	✓	✓
– zasoby	✓	✓	×	✓	×	✓	×	×
– NCF ^a	✓	✓	✓	✓	✓	✓	✓	✓
– NPV	✓	✓	✓	✓	✓	✓	✓	✓

^adotyczy modeli ze zmiennym zapotrzebowaniem na zasoby i/lub kapitał

Tab. 2.1: Kierunki optymalizacji w modelach harmonogramowania projektów

Modele bez ograniczeń

W literaturze spotkać można dwa rodzaje modeli harmonogramowania projektu bez ograniczeń (ang. UPS – *Unconstrained Project Scheduling*): (1) ukierunkowane na minimalizację czasu trwania lub (2) ukierunkowane na maksymalizację NPV dla znanych wielkości przepływów pieniężnych związanych z realizacją czynności. Model bez ograniczeń z optymalizacją czasu zakończenia może być rozwiązany w czasie wielomianowym przez prostą rekursywną procedurę, która przypisuje czynności najwcześniejszy możliwy czas rozpoczęcia zgodnie z ograniczeniami kolejnościowymi⁶. Problem maksymalizacji NPV wprowadził Russell (1970) analizując model z wydatkami przy rozpoczęciu realizacji poszczególnych czynności i wpływami z tytułu zakończenia określonych zbiorów prac. Etgar i Shtub (1999) analizują model UPS z liniową zależnością wielkości przepływów pieniężnych od czasu wystąpienia zdarzenia w sieci AOA.

Modele z ograniczeniami czasowymi

Model z ograniczeniami czasowymi (ang. TCPS – *Time Constrained Project Scheduling*) stanowi rozwinięcie UPS uwzględniające występowanie ograniczeń czasowych realizacji czynności. Ograniczenia czasowe mogą mieć dwojaki charakter: (1) **względny** – w przypadku określenia minimalnych i maksymalnych opóźnień w ogólnym modelu relacji (patrz p. 2.1) lub (2) **bezwzględny** poprzez określenie okna czasowego (ang. *time window*), czyli najwcześniejszego i/lub najpóźniejszego możliwego terminu realizacji. Termin okna czasowego bywa również używany dla określenia opóźnień czasowych w relacjach (m.in. Möhring, Schulz, Stork i Uetz (1999)) lub też terminy te bywają używane zamiennie (m.in. Uetz (2001)). W niniejszym opracowaniu przyjęto używanie terminu opóźnienia (zwłoki) dla określenia względnych, natomiast okna czasowego dla określenia bezwzględnych ograniczeń czasowych. Przykładem ograniczeń względnych może być wstrzymanie realizacji dalszych pracy budowlanych po wylaniu fundamentów do czasu ich związania, ograniczeniem bezwzględnym będzie np. konieczność zakończenia prac elewacyjnych przed zimą, czy narzucony termin zakończenia prac.

Pawlak (1999) konstruuje model z kryterium optymalizacji opartym na profilu wykorzystania nieograniczonych zasobów, na które zapotrzebowanie jest znane i określone na poziomie czynności.

Drugą grupę stanowią modele TCPS z przepływami gotówki zorientowane na maksymalizację NPV. Po raz pierwszy model tego typu sformułował Grinold (1972). Vanhoucke, Demeulemeester i Herroelen (2001a) analizują problem TCPS (oznaczony jako UPS *with deadlines*) z liniową zależnością pomiędzy terminem realizacji czynności, a wielkością przepływu gotówki. Vanhoucke, Demeulemeester i Herroelen (2002b)

⁶Podobnie jak w przypadku metody CPM, która dodatkowo analizuje najpóźniejszy możliwy termin wykonania czynności (poprzez analogiczną rekursywną procedurę przeprowadzoną dla terminów zakończenia rozpoczynając od ostatniej czynności) i uzyskując w efekcie informację o zapasie czasu dla czynności (ścieżce krytycznej dla projektu). Podobnie w metodzie PERT wyznaczane są terminy realizacji czynności. Różnica pomiędzy obiema metodami polega na traktowaniu w metodzie PERT czasu trwania zadania jako zmiennej losowej poprzez oszacowanie czasu oczekiwanego zakończenia zadania (na podstawie trzech zmiennych: czasu optymistycznego, czasu realistycznego i czasu pesymistycznego), który jest podstawą analizy ścieżki krytycznej oraz wariancji czasu oczekiwanego, która określa spodziewaną różnicę szacowanego czasu oczekiwanego zakończenia zadania od rzeczywistego czasu trwania czynności.

rozważają problem TCPS z płatnościami rozłożonymi równomiernie w czasie. Schwindt i Zimmermann (2001) przedstawiają model TCPS z ogólnym modelem relacji.

Modele z ograniczonymi zasobami

Najczęściej podejmowanym w badaniach rozwinięciem UPS jest klasa problemów harmonogramowania projektu z ograniczonymi zasobami. Punktem wyjścia do rozważań jest w każdym przypadku ogólny problem harmonogramowania projektu z ograniczoną dostępnością zasobów (ang. RCPS – *Resource-Constrained Project Scheduling*). Model składa się z wzajemnie powiązanych ze sobą relacjami typu $\mathbb{Z}\mathbb{R}$ czynności, które wymagają do realizacji zaangażowania zasobów z ograniczoną dostępnością (patrz p. 2.1). Stork i Uetz (2001) porównują modelowanie ograniczeń zasobów w formie poziomu dostępności (ten sposób nazywają *threshold representation*) i w formie zbiorów zabronionych (ang. *minimal forbidden set representation*). Zbiory zabronione stanowią zbiory czynności, których jednoczesne wykonanie nie jest możliwe z uwagi na ograniczoną dostępność zasobów.

Początkowo model RCPS traktowany był jako dalsze uogólnienie ogólnego modelu harmonogramowania, poprzez wprowadzenie relacji kolejnościowych pomiędzy czynnościami z różnych ścieżek. Davis i Heidorn (1971) opisują kolejne uogólnienie modelu poprzez wprowadzenie możliwości przypisywania wielu zasobów do realizacji czynności, tak zdefiniowany model określają jako *Multiple RCPS*. Demeulemeester i Herroelen (1996) podejmują rzadko uwzględniany w badaniach model z rugowaniem czynności. W klasie modeli RCPS rozróżnić można jeszcze: (1) modele bez przepływów pieniężnych pozwalające na stosowanie kryteriów czasowych oraz (2) modele z przepływami pieniężnymi pozwalające na stosowanie kryteriów ekonomicznych. Pierwszą grupę problemów rozważają m.in. Böttcher, Drexler, Kolisch i Salewski (1999), Davis i Heidorn (1971), Hartmann (2002), Icmeli i Rom (1996), Kolisch i Hartmann (1999), Thomas i Salhi (1998), Ulusoy i Özdamar (1994), Yoo, Yang i Ignizio (1995). Modelami RCPS z przepływami pieniężnymi zajmują się m.in. Baroum i Patterson (1996), Icmeli i Erenguc (1996a), Icmeli i Rom (1996), Kimms (2001), Özdamar i Ulusoy (1996a), Pinder i Maruchek (1996). Icmeli i Erenguc (1996b) rozważają problem RCPS z przepływami pieniężnymi i dodatkowo zależnością czas/koszt. Mori i Tseng (1997), Sung i Lim (1997) szukają rozwiązania modelu RCPS z dyskretną zależnością czas/zasób.

Modele z ograniczonym kapitałem

Doersch i Patterson (1977) wprowadzili po raz pierwszy ograniczenie kapitału w harmonogramowaniu projektu rozwijając model UPS z przepływami gotówki, który opisał Russell (1970). Nowym elementem w konstrukcji modelu jest założenie ograniczonej wielkości dostępnego wraz z rozpoczęciem projektu kapitału. Wielkość kapitału dostępna w kolejnych okresach zależna jest od przepływów związanych z umieszczonymi w harmonogramie czynnościami. Zmiany wielkości kapitału określane są poprzez: (1) wydatki ponoszone z tytułu rozpoczęcia realizacji czynności (wiążane są one z kosztami realizacji czynności – materiały, koszty użytkowania zasobów) i (2) wpływy przekazywane przez klienta w momencie zakończenia wybranych prac, które to wpływy mogą być reinwestowane w realizowany projekt. Chociaż możliwe jest modelowanie ograniczonego kapitału w formie zasobu nieodnawialnego (Talbot, 1982) lub podwójnie ograniczonego (Talbot, 1982, Węglarz, 1981), został on wyodrębniony ze względu na szczególne cechy, które są pomijane w przypadku modelowania go w formie zasobu. Smith-Daniels, Padman i Smith-Daniels (1996) zauważają, że wielkość dostępnego kapitału w trakcie realizacji projektu wynika z posiadanych na początku środków oraz ze zrealizowanych płatności w trakcie realizacji. W odróżnieniu od zasobów, poziom dostępnego kapitału jest wielkością dynamiczną – stanowi funkcję przepływów pieniężnych związanych z umieszczonymi w harmonogramie czynnościami. Model z kapitałem (ang. CCPS – *Capital Constrained Project Scheduling*) jako jedynym ograniczeniem sformułowali Smith-Daniels, Padman i Smith-Daniels (1996). Znacznie częściej ograniczenie kapitałowe uwzględniane jest w połączeniu z ograniczeniami czasowymi lub zasobowymi.

Modele z ograniczonym czasem i zasobami

Model z ograniczeniami czasowymi i zasobowymi (ang. TRCPS – *Time & Resource Constrained Project Scheduling*) można potraktować jako rozszerzenie modelu RCPS polegające na wprowadzeniu ograniczeń czasowych dowolnego rodzaju.

Elmaghraby i Kamburowski (1992) analizują ogólny model relacji pomiędzy czynnościami, pozwalając modelować z wykorzystaniem czterech rodzajów relacji (opisanych w p. 2.1). Sformułowany ogólny model relacji zaopatrzony zostaje w ocenę wykonalności i krytyczności poszczególnych czynności. Z uwagi na możliwość redukcji różnorodności relacji do jednego typu z pomocą opóźnień (Bartusch i in., 1988) znaczna większość konstruowanych modeli oparta jest na jednym rodzaju relacji pomiędzy czynnościami. Bartusch, Möhring i Radermacher (1988) analizują model z jednocześnie ograniczonymi zasobami i czasem. Dorndorf, Phan-Huy i Pesch (1998) proponują testy zgodności okresowej zapotrzebowania na zasoby w modelu TRCPS wykorzystywane w wyodrębnianiu minimalnych zbiorów zabronionych. Klein (2000), Klein i Scholl (1999) przedstawiają model TRCPS z ograniczeniami zasobów zależnymi od czasu i ograniczeniami czasowymi zarówno względnymi, jak i bezwzględnymi. Möhring, Schulz, Stork i Uetz (1999) szukają efektywnych metod obliczania dolnych ograniczeń w modelu z ograniczonymi zasobami i względnymi ograniczeniami czasowymi. Neumann i Zimmermann (2000) kierują się kryterium NPV w modelu z ograniczonymi zasobami i względnymi ograniczeniami czasowymi. Özdamar, Ulusoy i Bayyigit (1998) wskazują na konflikt pomiędzy maksymalizacją NPV, a minimalizacją opóźnień w modelu z ograniczonymi zasobami, narzuconym terminem zakończenia i przepływami pieniężnymi. Vanhoucke, De-meulemeester i Herroelen (2001b) szukają rozwiązania takiego samego problemu z maksymalnym NPV. Fest, Möhring, Stork i Uetz (1999) badają model z względnymi ograniczeniami czasowymi i zasobami reprezentowanymi w formie zbiorów zabronionych. Baptiste, Pape i Nuijten (1999) oraz Baptiste i Pape (2000) przedstawiają model z ograniczonymi zasobami i bezwzględnymi ograniczeniami czasowymi określając go mianem *cumulative scheduling problem*.

Modele z ograniczonym czasem i kapitałem

Doersch i Patterson (1977) przedstawiają model TCCPS (ang. *Time & Capital Constrained Project Scheduling*) z ograniczeniami bezwzględnym w postaci terminu zakończenia projektu i ograniczeniami kapitału jak w modelu CCPS. Özdamar i Dündar (1997) konstruują model z ograniczeniami czasowymi i kapitałowymi uwzględniając dwojako ograniczenia czasowe: (1) na poziomie relacji w formie opóźnień oraz (2) określając wymagany termin zakończenia projektu. W modelu przepływów finansowych uwzględniają stopę oprocentowania dla kapitału pożyczanego oraz przychody finansowe z kapitału nie skonsumowanego.

Modele z ograniczonymi zasobami i kapitałem

Bianco, Dell’Olmo i Speranza (1998) konstruują model RCCPS (ang. *Resource & Capital Constrained Project Scheduling*). W swoim modelu przyjmują, że czynności korzystające z tego samego zasobu nie mogą być realizowane jednocześnie (co w efekcie oznacza liczebność zasobów równą 1). Również ograniczenia kapitału przyjęte są tu w uproszczonej formie. Z każdą z czynności związany jest określony koszt realizacji. Budżet projektu stanowi ograniczenie dla wyboru sposobów realizacji czynności. Przedmiotem optymalizacji jest czas zakończenia projektu.

Modele z ograniczonym czasem, zasobami i kapitałem

Model TRCCPS (ang. *Time, Resource & Capital Constrained Project Scheduling*) przyjmuje ograniczenia czasowe, zarówno względne i bezwzględne, ograniczone zasoby dowolnych rodzajów oraz ograniczenie kapitału. Teoretycznie możliwe jest sformułowanie i rozwiązanie tak postawionego problemu, jednak brak jest opisu badań w tym zakresie. Model tego rodzaju winien być rozważany dla maksymalizacji NPV (możliwe jest ewentualnie kierowanie się kryterium terminu zakończenia). Wydaje się, że właśnie tak sformułowany model miałby największe znaczenie praktyczne w rozwiązywaniu problemów, przed którymi stają kierownicy, czy zarządzający projektami.

2.6 Metody harmonogramowania projektów

Klasyfikację algorytmów harmonogramowania przedstawia m.in. Brucker (1995) w zakresie problemów jedno- i wielo-maszynowych o strukturze otwartej, przepływowej, czy ogólnej. Metody stosowane w harmonogramowaniu projektów oparte są na podejściach stosowanych w rozwiązywaniu problemów typu ogólnego. Ze względu na efekt działania metod harmonogramowania wyróżnić można: m. dokładne i m. heurystyczne. Wśród metod dokładnych można wyróżnić: programowanie liniowe, programowanie dynamiczne oraz metody wyliczeniowe (podziału i ograniczeń, pośrednie wyliczenie). Metody heurystyczne bazują na założeniu, że dla problemów nierozwiązywalnych w czasie wielomianowym znalezienie rozwiązania optymalnego jest bardzo czasochłonne, a możliwe jest uzyskanie rozwiązań suboptymalnych we względnie krótkim czasie. Wśród metod heurystycznych wyróżnić można dwie grupy: heurystyki priorytetowe oraz metaheurystyki.

2.6.1 Metody dokładne

W przypadku problemów klasy UPS z optymalizacją czasu realizacji powszechnie stosowana jest metoda ścieżki krytycznej (ang. CPM – *Critical Path Method*). CPM pozwala określić najwcześniejsze i najpóźniejsze terminy realizacji czynności zapewniające minimalny czas trwania projektu poprzez prostą procedurę rekurencyjną.

Programowanie liniowe

Bowman (1959) jako jeden z pierwszych sformułował problem szeregowania-harmonogramowania w formie programu liniowego. Pritsker, Watters i Wolfe (1969) przedstawiają liniowy program 0–1 dla wieloprojektowego modelu TRCPS z uwzględnieniem narzuconego terminu zakończenia projektu. Opisują trzy kierunki optymalizacji: (1) minimalizację czasu realizacji projektów, (2) minimalizację opóźnienia realizacji projektów oraz (3) minimalizację kary za opóźnienie. Russell (1970) stosuje dualny program liniowy do rozwiązania problemu UPS z przepływami pieniężnymi. Patterson i Huber (1974) stosują programowanie 0–1 w ramach metody podziału i ograniczeń dla rozwiązania problemu RCPS. Doersch i Patterson (1977) wprowadzili binarny model liniowy dla problemu RCCPS. Autorzy przedstawili rozwiązania zadań o rozmiarach od 15 do 20 czynności, przyznając, że rozwiązanie problemów o większej liczbie czynności jest nieefektywne czasowo. Premachandra (1993) stosuje programowanie liniowe do rozwiązania problemu TCPS z liniową zależnością kosztu od czasu realizacji i ograniczonym terminem realizacji projektu. Następnie autor konstruuje model oceny wielokryterialnej oparty na programowaniu celów (ang. *goal programming*). Arisawa i Elmaghraby (1972) rozwiązują problem harmonogramowania projektu z ogólnym modelem relacji i zmiennym kosztem realizacji za pomocą ułamkowego programu liniowego. Karshenas i Haber (1990) formułują binarny model programowania liniowego dla optymalizacji kosztów wykorzystania zasobów. Powszechnie zauważana jest niepraktyczność programowania liniowego w rozwiązywaniu problemów harmonogramowania projektów (m.in. Błażewicz, Cellary, Słowiński i Węglarz (1979), Doersch i Patterson (1977), Patterson i Huber (1974), Wiest (1964, 1967)). Wynika to ze złożoności modelu (liczby zmiennych i równań) oraz niemożności zbudowania modelu z wieloma różnie sformułowanymi ograniczeniami.

Programowanie dynamiczne

Lofts (1974) rozwiązuje optymalnie problem RCPS z wykorzystaniem programowania dynamicznego, stosując jednocześnie koncepcję kombinacji dozwolonych (ang. *legal combinations*) stanowiących zbiory czynności, które mogą być realizowane jednocześnie w ramach ograniczeń kolejnościowych i dostępności zasobów. Gupta, Kyparisis i Ip (1992) wykorzystują programowanie dynamiczne dla selekcji projektów do wykonania i określenia kolejności ich realizacji w celu uzyskania maksymalnego NPV. Tavares (1986) stosuje programowanie dynamiczne dla optymalizacji przepływów pieniężnych przy realizacji dużych projektów budowy sieci kolejowej w Portugalii, natomiast Senouci i Eldin (1996) do harmonogramowania

projektów z wielokrotnie liniowo powtarzanymi sekwencjami czynności (znajdujące zastosowanie np. w budowie dróg, wieżowców).

Metody enumeratywne

Metody enumeratywne rozpoczynają poszukiwanie od częściowego harmonogramu uwzględniającego część ograniczeń i/lub czynności. Kolejno uwzględniane są dalsze ograniczenia i/lub czynności, aż do uzyskania kompletnego optymalnego harmonogramu. W każdej iteracji podejmowane są decyzje dotyczące kierunku dalszych poszukiwań, które są zwykle reprezentowane w postaci drzewa. Różnice występują na etapie budowy częściowego harmonogramu i reprezentacji węzłów drzewa. Dodatkowo stosowane są metody ograniczające zakres poszukiwań oparte na: dolnym lub górnym oszacowaniu (ang. *lower/upper bound*) lub dominacji. Poniżej przedstawiono wybrane badania w zakresie metod enumeratywnych w harmonogramowaniu realizacji projektów.

Mason i Moodie (1971) stosują metodę podziału i ograniczeń dla minimalizacji kosztu (uwzględniając koszty opóźnienia realizacji projektu oraz koszt zwiększenia/zmniejszenia poziomu zaangażowania zasobów) w modelu TCPS. Patterson (1984) przedstawia analizę porównawczą trzech metod enumeratywnych dla problemu RCPS: (1) ograniczonego wyliczania (ang. *bounded enumeration*), którą opisali Davis (1969) oraz Davis i Heidorn (1971), (2) podziału i ograniczeń (ang. *branch & bound*), którą sformułowali Stinson (1976), Stinson, Davis i Khumawala (1978) oraz (3) wyliczenia pośredniego (ang. *implicit enumeration*), którą proponują Talbot (1976), Talbot i Patterson (1978). Davis (1969) rozpoczyna od budowy sieci czynności jednostkowych (ang. *unit-duration tasks*) poprzez zamianę każdej z oryginalnych czynności na łańcuch czynności o jednostkowym czasie trwania połączonych szeregowo ze sobą, których liczba odpowiada liczbie jednostek czasu trwania czynności oryginalnej. W kolejnych etapach określane są podzbiory czynności wykonalnych, czyli takich których realizacja zgodnie z założoną kolejnością nie narusza ograniczonych zasobów. Na podstawie tychże zbiorów tworzona jest A-sieć (ang. *A-network*) zależności pomiędzy nimi, w której najkrótsza droga stanowi rozwiązanie optymalne problemu. W trakcie budowy A-sieci stosowane są kryteria eliminacji oparte na relacjach kolejnościowych i ograniczonych zasobach. Stinson (1976) buduje drzewo wyliczeń złożone z harmonogramów uwzględniających podzbiór czynności. Na każdym etapie do harmonogramu włączane są kolejne czynności, które mogą być wykonane ze względu na założone ograniczenia kolejnościowe. Rozgałęzienia drzewa powstają poprzez rozważanie różnych reguł rozdziału zasobów pomiędzy czynności, które powodują konflikt. Stinson stosuje trzy dolne ograniczenia dla zawężenia przestrzeni poszukiwań: (1) kolejnościowe – obliczone poprzez przypisanie najwcześniejszych możliwych terminów realizacji czynnościom nieumieszczonym w harmonogramie, (2) zasobowe – obliczone jako suma najwcześniejszych terminów czynności nieumieszczonych w harmonogramie powiększonych o iloraz zapotrzebowania okresowego na zasób przez dostępność tegoż zasobu w okresie oraz (3) *critical sequence* – obliczone z równoczesnym uwzględnieniem ograniczeń kolejnościowych i zasobowych (na podstawie Wiest (1964)). Ponadto Stinson stosuje regułę dominacji dla odrzucenia harmonogramów, w których czynność może być przesunięta w lewo (ang. *left-shift dominance pruning*) bez naruszenia ograniczeń. Talbot (1976) określa okna czasowe dla czynności, buduje najpierw harmonogram wprzód, a następnie wstecz od górnego ograniczenia czasu zakończenia. Czynności są umieszczane w najwcześniejszych możliwych terminach, jeżeli nie jest to możliwe ostatnia czynność jest opóźniana o jeden okres. Dla ograniczenia przestrzeni poszukiwań stosuje regułę eliminacji częściowych rozwiązań, które nie pozwolą na uzyskanie *dobrych* (czyli takich, które pozwolą na przypisanie jak najwcześniejszych terminów realizacji czynności) rozwiązań całkowitych poprzez koncepcję odcięć sieci. Dla poprawy efektywności algorytmu do dalszego rozważania zachowywana jest określona poprzez parametr *Z* liczba *dobrych* harmonogramów częściowych. Demeulemeester i Herroelen (1992) opisują algorytm podziału i ograniczeń dla modelu RCPS. Węzły drzewa rozwiązań reprezentują częściowe harmonogramy uwzględniające zależności kolejnościowe i ograniczenia zasobów. Kolejne węzły drzewa tworzone są poprzez wybór spośród minimalnych zbiorów czynności wymagających opóźnienia z powodu braku zasobów (ang. *minimal delaying alternatives*). Konflikt zasobu jest rozwiązywany poprzez dodatkową relację pomiędzy czynnościami. Liczba gałęzi drzewa jest dodatkowo ograniczana przez dwie reguły dominacji: (1) przesunięcia czynności w lewo (Stinson (1976)) oraz (2) opartą na koncepcji odcięć (Talbot (1976)). Icmeli i Erenguc (1996a) proponują metodę podziału i ograniczeń dla modelu TRCPS z dyskontowaniem przepływów pieniężnych

opartą na procedurze, którą opracowali Demeulemeester i Herroelen. Brucker (2002), Brucker, Knust, Schoo i Thiele (1998) przedstawiają metodę podziału i ograniczeń dla problemu RCPS z minimalizacją czasu realizacji. Definiują cztery rodzaje relacji, jakie mogą wystąpić pomiędzy dwoma czynnościami: (1) r. konjunktywna (ang. *conjunction*) – dla czynności połączonych relacją ZR, (2) r. dysjunktywna (ang. *disjunction*) – dla czynności realizowanych z wykorzystaniem tych samych zasobów, (3) r. równoległości (ang. *parallelity relation*) – dla czynności, które mają być wykonywane jednocześnie przez co najmniej jeden okres czasu oraz (4) r. elastyczności (ang. *flexibility relation*) – pozwala na dowolne umieszczenie czynności w harmonogramie. Węzeł drzewa określony jest poprzez cztery zbiory odpowiadające czterem rodzajom relacji. Przy inicjacji w zbiorze relacji dysjunktywnych znajdują się te pary czynności, których suma zapotrzebowań przekracza dostępny poziom zasobu, zbiór relacji równoległości jest pusty, natomiast w zbiorze relacji elastyczności znajdują się wszystkie pary czynności, które nie są połączone konjunktywnie lub dysjunktywnie. Generowanie kolejnych węzłów polega na wybraniu jednej relacji elastyczności i zamienieniu jej na relację dysjunktywną lub równoległą. Przegląd odbywa się do momentu przekształcenia wszystkich relacji elastyczności w inny rodzaj. Autorzy zakładają przeglądanie zbioru harmonogramów aktywnych, tak więc zdefiniowanie rodzajów relacji równoznaczne jest ze zdefiniowaniem harmonogramu. Zastosowane są trzy kryteria odrzucenia węzła: (1) natychmiastowe odrzucenie (adoptowane z procedury dla ogólnych problemów harmonogramowania, którą opisują Carlier i Pinson (1989)) po przekształceniu problemu RCPS w problem ogólny z dwoma czynnościami (2) ograniczenie dolne oparte na modelu liniowym z pominięciem ograniczeń kolejnościowych i dozwoleń rugowania (opisane przez Mingozzi, Maniezzo, Ricciardelli i Bianco (1998)) oraz (3) oszacowanie górne za pomocą procedury tabu search. Reyck i Herroelen (1998) przedstawiają metodę podziału i ograniczeń dla modelu TRCPS z ogólnym modelem relacji w celu minimalizacji czasu realizacji. Stanowi ona rozwinięcie procedury, którą opisali Demeulemeester i Herroelen (1992) z rozszerzeniem koncepcji minimalnych zbiorów czynności wymagających opóźnienia określonej mianem minimalnych sposobów opóźnienia (ang. *minimal delaying modes*). Węzeł reprezentowany jest poprzez oryginalną sieć projektu rozszerzoną (w ramach procesu przeglądania) o relacje dodane dla rozwiązywania konfliktów zasobów. Autorzy zapewniają o dużej elastyczności procedury i możliwości jej stosowania w szerokim zakresie problemów. Fest, Möhring, Stork i Uetz (1999) proponują metodę podziału i ograniczeń dla modelu TRCPS opartą również na rozwiązywaniu konfliktów zasobowych jednak nie za pomocą relacji, lecz poprzez dynamiczne określenie najwcześniejszej dozwolonej daty rozpoczęcia (ang. *release date*). Demeulemeester, de Reyck i Herroelen (2000) stosują metodę podziału i ograniczeń w modelu RCPS ze dyskretną zależnością czas/zasób w celu minimalizacji czasu zakończenia projektu. Wykorzystują koncepcję wykonalnych zbiorów par czynność-sposób wykonania. W kolejnych etapach przeglądania drzewa dla częściowego harmonogramu analizowane są wszystkie maksymalne wykonalne zbiory par czynność-sposób wykonania (maksymalne oznacza, że zwiększenie liczby czynności w zbiorze o jeden spowoduje niedotrzymanie ograniczenia dostępności zasobu) z uwzględnieniem czynności już umieszczonych w harmonogramie, lecz jeszcze nie zakończonych. Sprecher i Drexler (1996a,b, 1998) przedstawiają metodę podziału i ograniczeń opartą na algorytmie, który opisał Talbot (1976), Talbot i Patterson (1978) wraz z późniejszymi modyfikacjami (które przedstawili Patterson, Słowiński, Talbot i Węglarz (1990)). Autorzy rekonstruują algorytm dla warunków problemu RCPS z wieloma sposobami wykonania czynności dla optymalizacji kryteriów regularnych. Mingozzi, Maniezzo, Ricciardelli i Bianco (1998) opierają się na koncepcji zbiorów dopuszczalnych, czyli zbiorów czynności, które mogą być wykonywane jednocześnie bez naruszenia ograniczeń zasobów. Na tej podstawie formułują model programowania 0–1 z liczbą zmiennych odpowiadającą wszystkim zbiorom dopuszczalnym. Algorytmu podziału i ograniczeń wykorzystuje tenże model dodając nowe ograniczenia ściślejsze niż te, które proponują Stinson, Davis i Khumawala (1978) oraz nowe kryteria dominacji. Sprecher (2000) przedstawia algorytm podziału i ograniczeń dla problemu RCPS z minimalizacją czasu realizacji projektu. Drzewo wyliczeń budowane jest w oparciu o schemat, który przedstawili Patterson, Słowiński, Talbot i Węglarz (1990). Węzły potomne drzewa zbudowane są z czynności, które mogą zostać umieszczone w harmonogramie częściowym utworzonym z tych czynności, które znajdują się na ścieżce od wierzchołka do węzła rodzicielskiego (czyli tych, które zostały wybrane w poprzednich węzłach). Dorndorf, Pesch i Phan-Huy (2000a,b) stosują metodę podziału i ograniczeń opartą na propagacji ograniczeń do rozwiązania problemu TRCPS z ogólnym modelem relacji. Stork (2000) stosuje metodę podziału i ograniczeń do stochastycznego modelu harmonogramowania projektu. Gutjahr, Strauss i Wagner (2000) stosują metodę podziału i

ograniczeń w stochastycznym modelu harmonogramowania projektu z dyskretną zależnością czas/zasób. Do wyboru węzłów stosują metodę poszukiwania lokalnego. Achuthan i Hardjawidjaja (2001) używają metody podziału i ograniczeń do rozwiązania problemu TCPS z kosztem realizacji zależnym od czasu i karą za nieterminowość realizacji projektu. Franck, Neumann i Schwindt (2001) stosują metodę podziału i ograniczeń z odcięciami do rozwiązania problemu TRCPS. Heilmann (2003) stosuje metodę podziału i ograniczeń do rozwiązania problemu TRCPS z dyskretną zależnością czas/zasób (w postaci sposobów wykonania czynności). Klein i Scholl (1999) stosują poszukiwanie rozproszone (ang. *scatter search*) do sterowania procesem poszukiwania rozwiązania w ramach metody podziału i ograniczeń dla problemu TRCPS. Jednak metoda ta nie gwarantuje odnalezienia rozwiązania optymalnego.

2.6.2 Heurystyki priorytetowe

Brucker (2002) zaznacza, że dla rozwiązania problemu RCPS średniego czy dużego rozmiaru, konieczne jest zastosowanie metod heurystycznych. Jako najważniejszą grupę wymienia heurystyki oparte na priorytetach zwane dalej również algorytmami listowymi.

Heurystyki priorytetowe stanowią obszerną grupę metod składających się zwykle z dwóch elementów: (1) schematu harmonogramowania (ang. *schedule generation scheme*) oraz (2) reguły priorytetu (ang. *priority rule*). Schemat harmonogramowania stanowi jądro większości metod heurystycznych. Jego zadaniem jest zbudowanie harmonogramu uwzględniającego narzucone ograniczenia. W każdej iteracji tworzony jest harmonogram częściowy poprzez uzupełnienie harmonogramu z iteracji poprzedniej o kolejne czynności. Stosowane są dwa rodzaje procedur: (1) szeregowo (ang. *serial scheduling scheme*), oparte na przyroście czynności i (2) równoległe (ang. *parallel scheduling scheme*) oparte na przyroście czasu. Szczegółowy opis wraz z formalizmem algorytmicznym znajduje się w p. 5.2. Wróblewski i Krawczyński (1985) dla problemów harmonogramowania przepływu produkcji definiują **regułę priorytetu** jako, funkcję przypisującą każdej z operacji oczekujących na wykonanie w kolejce przed rozpatrywanym stanowiskiem, wartość wskaźnika priorytetu i wybierającą operację z minimalną lub maksymalną wartością tego wskaźnika określając tym samym, że operacja ta ma być wykonana w danej chwili w pierwszej kolejności. Dla problemów projektowych uwzględniając potrzebę zastosowania reguły priorytetu do schematu budowy harmonogramu można uznać, że regułą priorytetu stanowi funkcję przypisującą każdej z czynności możliwych (rozważanych) do umieszczenia w harmonogramie określoną **wartość wskaźnika priorytetu** (w skrócie wartość priorytetu), która wyznacza kolejność w jakiej czynności mają być umieszczane w harmonogramie. Reguły priorytetu można podzielić w zależności od (Kolisch i Hartmann, 1999):

- rodzaju wykorzystywanych informacji na: r. **sieciowe** – oparte na informacji o zależnościach kolejnościowych, r. **czasowe** – oparte na charakterystykach czasowych czynności (np. czas realizacji, termin wykonania, opóźnienie), r. **zasobowe** – oparte na informacji o zasobach (np. dostępność, zapotrzebowanie),
- zakresu wykorzystywanych informacji na: r. **lokalne** – wykorzystujące jedynie informacje o czynności dla której określana jest wartość priorytetu i r. **globalne** (ogólne) – wykorzystujące jakiegokolwiek inne informacje (np. o obciążeniu zasobu),
- zmienności wartości priorytetu na: r. **statyczne** – wartość priorytetu jest niezmienna w procesie budowy harmonogramu i r. **dynamiczne** – wartość priorytetu zależna jest od informacji o częściowo zbudowanym już harmonogramie (np. zapas czasu czynności, liczba czynności pozostałych do wykonania).

Połączenie opisanych dwóch elementów (reguły priorytetu i schematu budowy harmonogramu) w specyficzny algorytm można określić mianem heurystyki priorytetowej. W zależności od liczby generowanych harmonogramów metody te można podzielić na: (1) **jednoprzebiegowe** (ang. *single pass*) korzystające z jednej reguły priorytetu dla zbudowania jednego harmonogramu oraz (2) **wielo-przebiegowe** (ang. *multi pass*), które budują wiele harmonogramów w oparciu o jedną lub więcej reguł. Badaniem metod jednoprzebiegowych w modelach jedno-projektowych zajmują się m.in. Boctor (1990), Cooper (1976), Davis i Patterson (1975), DePuy i Whitehouse (2001), Elsayed (1982), Kolisch (1996a), Pinder i Maruchek

Oznaczenie	Wartość priorytetu	Priorytet
SPT (<i>Shortest Processing Time</i>)	czas realizacji czynności	min
MTS (<i>Most Total Successors</i>)	liczba wszystkich następników czynności	max
LFT (<i>Latest Finish Time</i>)	termin zakończenia realizacji wybranej czynności	max
MSLK (<i>Minimum SLack</i>)	zapas czasu	min
GRPW (<i>Greatest Rank Positional Weight</i>)	suma czasu realizacji wybranej czynności i jej bezpośrednich następników	max
EDD (<i>Earliest Due Date</i>)	narzucony termin zakończenia czynności	min
GSRR (<i>Greatest Successive Resource Requirements</i>)	całkowite zapotrzebowanie na zasoby ze strony wybranej czynności i jej następników	max
CFW (<i>Cash Flow Weight</i>)	suma przepływów pieniężnych związanych z wybraną czynnością i ze wszystkimi jej następnikami	max
DCFD (<i>Discounted Cash Flow based on activity Duration</i>)	wartość zdyskontowanego przepływu pieniężnego związanego z realizacją wybranej czynności, dyskontowanie oparte na czasie trwania tejże czynności	max
DCFEF (<i>Discounted Cash Flow at Early-Finish</i>)	wartość zdyskontowanych przepływów pieniężnych związanych z realizacją wybranej czynności, dyskontowanie oparte na najwcześniejszym terminie zakończenia według ścieżki krytycznej dla sieci bez ograniczonych zasobów	max
ΣDCFEF (<i>Discounted Cash Flow of Future activities at Early-Finish</i>)	wartość zdyskontowanych przepływów pieniężnych związanych z realizacją wybranej czynności i jej następników, dyskontowanie oparte na najwcześniejszym terminie zakończenia według ścieżki krytycznej dla sieci bez ograniczonych zasobów	max
RSM (<i>Resource Scheduling Method</i>)	największe opóźnienie terminu realizacji w zbiorze czynności do uruchomienia jakie spowoduje umieszczenie wybranej czynności w chwili bieżącej (czynności spośród których dokonywany jest wybór porównywane są parami dla określenia wzajemnych opóźnień jakie spowodują, wybierana jest ta, która powoduje najmniejsze opóźnienia)	min

Tab. 2.2: Wybrane reguły priorytetu stosowane w rozwiązywaniu problemów harmonogramowania projektów (Baroum i Patterson (1996), Davis i Patterson (1975), Kolisch (1996a,b), Kolisch i Hartmann (1999), Pinder i Maruchek (1996), Smith-Daniels, Padman i Smith-Daniels (1996)).

(1996), Thesen (1976) natomiast w modelach wielo-projektowych m.in. Allam (1988), Kurtulus i Davis (1982), Mohanty i Siddiq (1989). Wybrane reguły priorytetu przedstawiono w tab. 2.2. Boctor (1993) poza regułami określania kolejności wykonania, zajmuje się również regułami wyboru sposobu wykonania czynności w warunkach RCPS. Hartmann i Kolisch (2000), Kolisch (1996b), Kolisch i Hartmann (1999) dzielą dodatkowo metody wielo-przebiegowe na:

- **korzystające z wielu reguł priorytetu** – które zwykle budują określoną liczbę harmonogramów dla różnych reguł i jako rozwiązanie wybierają najlepszy (np. Khatatab i Choobineh (1991) stosuje 8 reguł priorytetu dla zbudowania 8 harmonogramów i wybrania najlepszego z nich). Boctor (1990) proponuje odmienne podejście, budując harmonogramy w oparciu o sumę ważoną wartości priorytetu według skończonej liczby reguł wybranych z wcześniej zdefiniowanego zbioru. Elsayed i Nasr (1986) korzysta z ważonej sumy dwóch reguł priorytetu (suma wag wynosi 1). Kolejne harmonogramy są budowane poprzez zmianę wag (zmianę stopnia dominacji jednej z reguł nad drugą).
- **próbkujące** – korzystające zwykle z jednej reguły priorytetu i jednego schematu harmonogramowania wprowadzając element losowości do wyboru czynności. Przegląd metod próbkowania wraz z analizą ich efektywności w zależności od rodzaju schematu budowy harmonogramu przedstawia Schirmer (1998). W przypadku próbkowania losowego (ang. *random sampling*) każda z czynności ubiegających się o zasób ma takie samo prawdopodobieństwo wyboru. Zastosowanie wyboru losowego opisują m.in. Cooper (1976), Crowston (1971), Wiest (1967). Yang, Tay i Sum (1995) określają wybór losowy mianem stochastycznych reguł priorytetu. Modyfikacją tego podejścia jest

próbki losowe z prawdopodobieństwem wyboru czynności proporcjonalnym do wartości priorytetu tejże czynności według wybranej reguły (ang. *biased random sampling*). Kolejną modyfikacją, którą proponuje Drexel (1991) jest uwzględnienie przy określaniu prawdopodobieństwa największej możliwej utraty wartości celu poprzez odrzucenie czynności (ang. *regret biased random sampling*). Otrzymana wartość może być dodatkowo skalowana wykładniczo. Schirmer i Riesenberga (1997) proponują dodatkowo normalizację wartości priorytetu w przypadku, gdy celem jest minimalizacja (wcześniej w badaniach stosowana była odwrotność wartości priorytetu – np. Cooper (1976)). Schirmer i Riesenberga (1998) zajmują się problemem ustalania schematów kontroli parametrów heurystyk priorytetowych oraz dla skrócenia czasu poszukiwania rozwiązania stosują dolne oszacowania. Schirmer (1999) proponuje metodę poszukiwania lokalnego opartą na adaptacyjnej kontroli parametrów używanych w procedurze budowy harmonogramu. W kolejnym podejściu Schirmer (2000) wykorzystuje *Case Based Reasoning* w procesie regulacji parametrów procedury budowy harmonogramu. Analizę porównawczą schematów kontroli parametrów (powyższych wraz z nowym schematem opartym na symulowanym wyżarzaniu) przedstawia Schirmer (2001).

- **korzystające z harmonogramowania wprzód i wstecz** (ang. *forward-backward scheduling method*) – Li i Willis (1992) przedstawiają procedurę, w ramach której kolejno budowane są harmonogramy *wprzód* i *wstecz*. Procedura *wstecz* realizowana po harmonogramowaniu *wprzód* ma tendencję do przesuwania czynności w prawo do najpóźniejszych możliwych terminów wykonania poprzez przypisanie wyższych wartości priorytetu czynnościom, które były uprzednio umieszczone później w harmonogramie. Konflikty zasobowe rozwiązywane są we wczesnych okresach harmonogramu. Budowanie nowego harmonogramu *wstecz* od terminu zakończenia projektu według uprzedniego harmonogramu *wprzód* może powodować umieszczenie czynności przed terminem rozpoczęcia projektu w przypadku gdy czas realizacji ulega wydłużeniu. Kolejne harmonogramowanie *wprzód* powoduje przesunięcie czynności w lewo. Procedura powoduje wyrównanie zapotrzebowania na zasoby, a co za tym idzie skrócenie terminu realizacji. Özdamar i Ulusoy (1996b) modyfikują tę metodę z zastosowaniem równoległego schematu budowy harmonogramu (w miejsce schematu szeregowego, który stosują Li i Willis (1992)) i dynamicznie określanych okien czasowych poprzez procedurę analizy lokalnych ograniczeń (ang. LCBA – *Local Constraint Based Analysis*), którą opisali Ulusoy i Özdamar (1994). Kolejną zasadniczą różnicą jest budowa harmonogramu *wstecz* od chwili 0 – czynności stają się dostępne po umieszczeniu w harmonogramie ich następników. W dalszych modyfikacjach Özdamar, Ulusoy i Bayyigit (1998) przedstawiają procedurę opartą na tych samych założeniach dla minimalizacji opóźnienia (lub czasu realizacji) i NPV w modelach z przepływami gotówki. Ulusoy i Özdamar (1995) uwzględniają dodatkowo możliwość realizacji czynności na wiele sposobów.

2.6.3 Metaheurystyki

Różnego rodzaju metaheurystyki stosowane są w optymalizacji problemów harmonogramowania projektów. Poczynając od prostych metod poszukiwania lokalnego, poprzez metody operujące na jednym rozwiązaniu, aż po metody populacyjne. Poniżej przedstawiono krótki przegląd przeprowadzonych badań, natomiast charakterystykę wybranych metod wraz z opisem implementacji przedstawiono w rozdziale 5. Wśród spotykanych w literaturze implementacji jedynie nieliczni autorzy podejmują tematykę optymalizacji charakterystyk ekonomicznych harmonogramu. Żadna z publikacji nie analizuje możliwości zastosowania metod metaheurystycznych w harmonogramowaniu wielu projektów jednocześnie bez względu na kierunek optymalizacji.

Poszukiwanie lokalne

Naphade, Wu i Storer (1997) definiują przestrzeń rozwiązań i otoczenie oraz konstruują algorytmy poszukiwania lokalnego dla problemu harmonogramowania projektu bazując na modelu przestrzeni rozwiązań, który przedstawiają Storer, Wu i Vaccari (1992, 1995).

Sampson i Weiss (1993) przedstawiają algorytm poszukiwania lokalnego dla problemu RCPS z nieregularnymi funkcjami kosztów. Rozwiązanie jest reprezentowane przez ciąg czasów rozpoczęcia czynności, natomiast otoczenie powstaje poprzez zwiększanie lub zmniejszanie opóźnienia względem najwcześniejszego terminu rozpoczęcia czynności. W przypadku rozwiązań nie spełniających ograniczeń wartość ruchu obciążona jest karą.

Leon i Balakrishnan (1995) rozważają problem RCPS z jednym sposobem wykonania czynności. Rozwiązanie jest kodowane w postaci ciągu wartości priorytetu czynności zgodnie z którymi następnie są one umieszczane w harmonogramie. Generowanie otoczenia odbywa się poprzez zmianę poszczególnych wartości w ramach ciągu wartości priorytetu. Wadą metody jest nadmierne zwiększenie przestrzeni poszukiwań, gdzie jedno rozwiązanie może być kodowane na wiele sposobów.

Kolisch i Drexl (1997) proponują metodę poszukiwania lokalnego dla problemu RCPS z wieloma sposobami realizacji czynności. Procedura składa się z trzech faz: (1) konstruowania wstępnego rozwiązania, (2) poszukiwania lokalnego poprzez zamianę sposobu wykonania dla losowo wybranej czynności oraz (3) intensyfikacji poszukiwania poprzez zastosowanie procedury, którą przedstawili Kolisch i Drexl (1996) dla odnalezienia suboptymalnego uszeregowania czynności w ramach wybranego ciągu sposobów wykonania czynności (problem sprowadza się do RCPS z jednym sposobem wykonania czynności).

Schirmer (1999, 2001) proponuje algorytmy poszukiwania lokalnego oparte na regułach priorytetu dla problemu RCPS z zasobami częściowo odnawialnymi. Rozwiązanie reprezentowane jest poprzez ciąg wag, z których każda odpowiada wybranej regule priorytetu. W procesie budowy harmonogramu priorytet czynności określany jest zgodnie z ważoną sumą wartości dla poszczególnych reguł. W procedurze poszukiwania najlepszej kombinacji wag reguł wykorzystywane są dwa rodzaje schematów kontroli: (1) stałe (ang. *FCS – Fixed Control Scheme*) w ramach których procedura powtarzana jest założoną liczbę razy z różnymi kombinacjami wag według założonej trajektorii (zbliżone do priorytetowych metod próbkujących) oraz (2) adaptacyjne (ang. *ACS – Adaptive Control Scheme*), gdzie ustalanie parametrów powierzone jest procedurze o pewnym stopniu losowości, która ustalając parametry kieruje się wynikami uzyskanymi w poprzednich iteracjach. Do FCS można zaliczyć metody, które prezentują m.in. Böttcher, Drexl, Kolisch i Salewski (1999), Schirmer i Riesenberga (1997), procedurę STOCOM, którą opisują Drexl i Grünwald (1993), oraz jej rozwinięcie z uwzględnieniem modelu z wieloma sposobami wykonania czynności procedurę RAMSES, którą prezentują Salewski, Schirmer i Drexl (1996a,b, 1997). Schirmer (1999, 2001) wyróżnia dodatkowo w ramach FCS metody dedykowane dla klas problemu (ang. *CCS – Class-based Control Scheme*), które w procesie ustalania parametrów kierują się charakterystyką problemu i dla określonych klas wykorzystują różne kombinacje parametrów (m.in. Schirmer i Riesenberga (1997, 1998)). W ramach ACS Schirmer opisuje dwa schematy doboru parametrów: (1) oparty na schemacie studzenia symulowanego wyżarzania (ang. *RCCS – Randomized Cooling Control Scheme*) oraz (2) oryginalny schemat poszukiwania lokalnego (ang. *LSCS – Local Search Control Scheme*), sklasyfikowany jako *steepest-descent search method*, który w kolejnych iteracjach zawęża obszar poszukiwań w oparciu o współczynnik ziarnistości siatki (ang. *grid granularity*).

Yoo, Yang i Ignizio (1995) proponują procedurę optymalizacji harmonogramu w warunkach RCPS dla kryterium minimalizacji czasu zakończenia. Proces poszukiwania rozpoczyna się od wylosowania harmonogramu aktywnego. Następnie po wybraniu czynności kluczowej (ang. *Target Activity*) realizowane są trzy kroki: (1) przesunięcie w prawo (ang. *RSMO – Right Shift Move Operation*) czynności angażujących zasoby uniemożliwiające przesunięcie w lewo czynności kluczowej, (2) przestawienie w lewo (ang. *LSMO – Left Shift Move Operation*) czynności kluczowej i przydzielenie jej zwolnionych w kroku 1 zasobów oraz (3) reorganizacja (ang. *REARRG – Rearranging Operation*) polegająca na przesunięciu w lewo czynności, które zostały w kroku 1 przeniesione w prawo. Realizacja tych kroków gwarantuje utrzymanie wykonalności harmonogramu. W przypadku gdy nie ma możliwości przeprowadzenia procedury dla wybranej czynności kluczowej, wybierana jest kolejna czynność – kryterium wyboru stanowi wielkość zapasu czasu względem terminu zakończenia ostatniego poprzednika.

Pierwszą próbę zastosowania SA w optymalizacji harmonogramu realizacji projektu podjął Boctor (1996b). Zbudował on procedurę dla problemu z ograniczonymi zasobami odnawialnymi oraz jej wersję dostosowaną do problemu z wieloma sposobami wykonania czynności. Boctor używa reprezentacji permutacyjnej z zachowaniem narzuconych relacji tzn. czynność występuje w sekwencji przed wszystkimi swoimi następnikami (model z relacjami typu ZR). Otoczenie generowane jest poprzez przemieszczenie wybranej czynności nie naruszając relacji, czyli na pozycję znajdującą się pomiędzy ostatnim poprzednikiem i pierwszym następnikiem. W eksperymentach obliczeniowych stosowane jest kryterium czasu zakończenia realizacji projektu, jednak Boctor stwierdza, że jego procedura jest w stanie optymalizować harmonogram projektu również ze względu na inne kryteria.

Lee i Kim (1996) przedstawiają implementację wybranych metaheurystyk (SA, TS, GA) w warunkach minimalizacji czasu realizacji projektu w modelu RCPS z jednym sposobem wykonania czynności. Wprowadzają do harmonogramowania projektów nowy sposób reprezentowania rozwiązania w formie ciąg wartości priorytetu⁷ o rozmiarze odpowiadającym liczbie czynności i wartościach z zakresu (0, 1). Otoczenie dla procedur SA i TS generowane jest poprzez zamianę wartości priorytetu dla dwóch wylosowanych czynności: pierwsza wybrana losowo, druga natomiast wylosowana spośród czynności oddalonych o αm od pierwszej (gdzie m jest maksymalną liczbą poprzedników lub następników, natomiast α stanowi parametr, którego wartość Autorzy ustalili na poziomie 4).

Cho i Kim (1997) modyfikują reprezentację, którą zaproponowali Lee i Kim (1996) pozwalając, aby wartości priorytetu miały znak zarówno dodatni, jak i ujemny. Czynności z wartościami ujemnymi będą opóźniane w realizacji zgodnie z zaproponowanymi procedurami opartymi na kryteriach odległości od czynności końcowej, czasu opóźnienia oraz liczby dokonanych opóźnień czynności. Specjalny sposób traktowania czynności opóźnionych ma pozwolić usunąć ograniczenie poprzedniej procedury (Lee i Kim, 1996), która przeszukiwała jedynie przestrzeń harmonogramów bez opóźnień. Opracowany sposób kodowania Autorzy testują w algorytmie SA.

Bouleimen i Lecocq (1998, 2000, 2003) proponują kolejne wersje algorytmu SA dla problemów harmonogramowania projektu z jednym i wieloma sposobami realizacji czynności ukierunkowane na minimalizację terminu wykonania. Otoczenie zdefiniowane jest w sposób, który opracował Boctor (1996b). Autorzy natomiast skupiają uwagę na rozbudowanej procedurze kontroli schładzania wykorzystującej informacje specyficzne dla zadania. Dodatkowo Bouleimen i Lecocq rozróżniają otoczenie określane mianem czynnościowego (ang. *activity neighbourhood*) zgodne z (Boctor, 1996b) oraz proponują nowy sposób generowania otoczenia sposobu wykonania czynności (ang. *mode neighbourhood*) poprzez zamianę sposobu wykonania losowo wybranej czynności na inny dozwolony dla tej czynności. Całość zorganizowana jest w dwuetapową procedurę poszukującą najpierw lepszego rozwiązania w otoczeniu czynnościowym, a następnie dla tegoż rozwiązania poszukiwane jest poprawione rozwiązanie w ramach otoczenia sposobu wykonania. Przedstawione wyniki analiz porównawczych wskazują, że jest to jedna z najskuteczniejszych metaheurystyk dla problemu RCPS.

Gemmill i Tsai (1997) przedstawiają procedurę SA dla rozwiązania problemów typu RCPS z uwzględnieniem deterministycznych i stochastycznych czasów realizacji czynności. Jako kierunek optymalizacji stosują czas zakończenia projektu. Podobnie jak Boctor (1996b), Gemmill i Tsai stosują reprezentację permutacyjną, jednak proponują inny sposób generowania otoczenia. Nową sekwencję czynności budują poprzez zamianę pozycji dwóch losowo wybranych czynności, co może powodować powstanie sekwencji naruszających ograniczenia kolejnościowe. W przypadku uzyskania uszeregowania naruszającego ograniczenia kolejnościowe generowana jest kolejna sekwencja aż do utworzenia dopuszczalnego uszeregowania. Zaproponowany sposób generowania otoczenia jest wysoce nieefektywny w porównaniu z koncepcją, którą przedstawia Boctor (1996b).

Józefowska, Mika, Różycki, Waligóra i Węglarz (2000, 2001) stosują SA dla rozwiązania problemu RCPS z wieloma sposobami wykonania czynności. W konstrukcji algorytmu korzystają ze sposobu reprezento-

⁷reprezentację tego rodzaju opisali wcześniej Bean (1994), Norman i Bean (1995), określając ją mianem *Random Keys Representation*; była ona stosowana w GA dla rozwiązania problemów harmonogramowania i wyboru lokalizacji (Norman i Bean (1999, 2000), Norman i Smith (1997))

wania rozwiązania i definicji otoczenia, które prezentują Bouleimen i Lecocq (2000). W odróżnieniu od tych ostatnich Józefowska, Mika, Różycki, Waligóra i Węglarz nie rozdzielają dwóch faz poszukiwania (w otoczeniu czynnościowym i wśród sposobów wykonania), pozwalając wykonywać ruch na jeden z trzech sposobów: (1) zmiana jedynie w uszeregowaniu czynności, (2) zmiana jedynie w sposobie wykonania, (3) zmiana zarówno w uszeregowaniu jak i sposobie wykonania. Wybór sposobu przeprowadzenia ruchu dokonywany jest losowo (ruch złożony z prawdopodobieństwem $1/2$, natomiast dwa pozostałe zależnie od topologii sieci). Autorzy przedstawiają adaptacyjny schemat studzenia, który ma zapobiegać przedwczesnej zbieżności i zatrzymaniu algorytmu w lokalnym minimum. Mika, Waligóra i Węglarz (2005) przedstawiają wyniki zastosowania podobnego rozwiązania SA ze względu na kryterium maksymalizacji NPV przy zróżnicowanych modelach płatności (wygenerowanych na podstawie problemów z biblioteki ProGen). Autorzy proponują dodatkowo wprowadzenie dla harmonogramów niewykonalnych korekty wartości kryterium (zamiast wyłączenia ich z procesu poszukiwania), która ogranicza stosowanie opisywanych metod do problemów o dodatnich wartościach przepływów pieniężnych. Wnioski z badań potwierdzają wyższość SA nad TS dla problemów o większej liczbie czynności. Wraz ze wzrostem liczby czynności do zaplanowania wzrasta efektywność SA niezależnie od modelu płatności.

Przeszukiwanie z ruchami zabronionymi

Podstawowe założenia algorytmu poszukiwania z ruchami zabronionymi (ang. TS – *Tabu Search*) przedstawili niezależnie Glover (1986) oraz Hansen (1986). Obecnie stosowaną formę opisał po raz pierwszy Glover (1989, 1990a,b). Opis procedur TS wraz z późniejszymi modyfikacjami przedstawiają m.in. Battiti i Tecchiolli (1994), Crainic, Toulouse i Gendreau (1997), Glover i Laguna (1997, 2002), Hertz, Taillard i de Werra (1997), Reeves (1995). Podstawowym składnikiem TS jest przeszukiwanie otoczenia dla odnalezienia najlepszego rozwiązania lokalnego. Dla uniknięcia ugrzęźnięcia w lokalnym optimum i cykliczności utrzymywana jest pamięć krótkoterminowa zwana listą tabu (listą ruchów zabronionych) zawierająca rozwiązania, które nie mogą zostać zaakceptowane. Jednym z podstawowych parametrów algorytmu jest długość listy tabu (ang. *tabu tenure*). Im większy dozwolony rozmiar listy tym większy jest nacisk na eksplorację przestrzeni rozwiązań, im lista krótsza tym intensywniej przeszukiwany jest bieżący fragment tejże przestrzeni. Taillard (1991) stosuje losowo zmienianą w procesie poszukiwania długość listy w ramach narzuconego dolnego i górnego ograniczenia.

Baar, Brucker i Kunst (1998) przedstawiają dwie wersje algorytmu TS: (1) opartą na reprezentacji permutacyjnej oraz (2) wykorzystującą reprezentację określoną mianem *Schedule Scheme Respresetation*, opartej na definicji, którą przedstawili Brucker, Knust, Schoo i Thiele (1998).

Verhoeven (1998) proponuje algorytm TS dla problemu RCPS oparty na reprezentacji w formie przydziałów zasobów do operacji w formie pary (ra, st) , gdzie ra określa przydział zasobu, natomiast st moment rozpoczęcia czynności. Rozwiązanie reprezentowane jest poprzez acykliczny graf skierowany $G = (O, E)$, gdzie zbiór wierzchołków O odpowiada zbiorowi czynności, natomiast zbiór krawędzi E określa kolejność realizacji czynności. Otoczenie jest generowane poprzez procedurę bazującą na obserwacjach, które opisują Nowicki i Smutnicki (1996) dla ogólnego problemu harmonogramowania. Konstrukcja algorytmu zakłada wykorzystanie elementów procedury unikania lokalnych minimów, którą przedstawili Nowicki i Smutnicki (1996).

Reyck i Herroelen (1999) stosują TS dla przeszukiwania otoczenia sposobów wykonania czynności w modelu oznaczonym jako MRCPSP-GPR (ang. *multi-mode resource-constrained project with generalized precedence relations*) z ukierunkowaniem na minimalizację czasu realizacji projektu. Dla wybranego sposobu wykonania czynności stosują procedurę heurystyczną dla problemu jedno-modalnego przedstawioną w pracy (Reyck i Herroelen, 1998).

Cavalcante i de Souza (1997) przedstawiają algorytm TS dla rozwiązania problemu harmonogramowania z ograniczoną liczbą stanowisk (określając go mianem *Scheduling Problem under Labour Constraints*) dla minimalizacji czasu realizacji projektu. Ograniczenie zasobowe stanowi dostępność pracowników, ujętych jako jeden zasób typu odnawialnego. Dla rozwiązania problemu autorzy posługują się reprezentacją permutacyjną, definiując otoczenie poprzez dwa rodzaje ruchów: (1) wymianę pozycji dwóch losowo wybranych czynności oraz (2) wstawienie wylosowanej czynności na losowo wybrane miejsce. Jedynie

ruchy zapewniające uzyskanie sekwencji spełniających ograniczenia kolejnościowe są brane pod uwagę. Ruchy zabronione są zdefiniowane na trzy sposoby (zgodnie z definicją ruchów): (1) czynność *j* została przeniesiona, (2) czynność *i* została wstawiona bezpośrednio przed czynnością *j* oraz (3) czynności *i* oraz *j* zostały wymienione. Cavalcante, Cavalcante, Ribeiro i de Souza (2000) rozwijają powyższą procedurę do równoległego TS.

Tsai i Gemmill (1998) przedstawiają algorytm TS dla problemu RCPS ze stochastycznie określonymi czasami czynności. W swojej procedurze wykorzystują reprezentację permutacyjną. Podobnie jak w pracy Gemmill i Tsai (1997) otoczenie jest generowane poprzez zamianę pozycji dwóch losowo wybranych czynności, co może powodować powstanie uszeregowan naruszających ograniczenia kolejnościowe. Losowanie jest powtarzane, aż do uzyskania wykonalnej permutacji.

Thomas i Salhi (1998) rozpatrują algorytm TS dla problemu RCPS z zasobami typu odnawialnego optymalizowanego pod kątem minimalizacji czasu zakończenia. Procedura operuje bezpośrednio na harmonogramie zdefiniowanym w postaci listy terminów rozpoczęcia czynności. Autorzy przedstawiają trzy rodzaje ruchów w otoczeniu: (1) zamiana czynności (ang. *activity swap*) – losowo wybierane są dwie czynności nie powiązane relacjami następnie zamieniane są ich terminy uruchomienia, (2 i 3) wstawienie czynności typu 1 lub 2 (ang. *activity insert type 1, 2*) – termin uruchomienia czynności jest ustawiany zgodnie z terminem uruchomienia (typ 1) lub zakończenia (typ 2) czynności znajdującej się w miejscu wstawienia. Lista ruchów zabronionych określa czy ruch każdego typu dla danej pary czynności może być zrealizowany. Przeprowadzenie ruchu może prowadzić do powstania harmonogramów naruszających ograniczenia zasobowe, autorzy wprowadzają karę zależną od stopnia naruszania ograniczeń zasobowych.

Dodin, Elimam i Rolland (1998) stosują algorytm TS dla harmonogramowania pracy audytorów przydzielanych do pracy w ramach wielu projektów. Autorzy modelują problem w formie programowania 0–1, a następnie do rozwiązania stosują algorytm TS silnie związany z modelem w zakresie generowania otoczenia.

Algorytmy genetyczne

Algorytmy genetyczne (ang. GA – *Genetic Algorithm*) dla harmonogramowania projektów oparte są na procedurach stosowanych z powodzeniem w harmonogramowaniu produkcji różnych typów (m.in. Cheng, Mitsuo i Tsujimura (1996), Falkenauer i Bouffouix (1991), Kimms (1996), Kobayashi, Ono i Yamamura (1995), Mattfeld (1995), Nakano i Yamada (1991), Yamada i Nakano (1992, 1995, 1996, 1997), Yamada i Reeves (1997)).

Cheng i Gen (1994) przedstawiają dla problemu RCPS procedurę GA, która wykorzystuje reprezentację opartą na liście czynności wraz z czasami ich rozpoczęcia. Dla przeprowadzenia rekombinacji stosują operatory permutacyjne wsparte specjalnymi procedurami naprawy dla uwzględnienia zależności kolejnościowych i ograniczeń zasobowych. Lee i Kim (1996) dla rozwiązania problemu RCPS stosują GA z reprezentacją w postaci ciągu wartości priorytetu. Harmonogram budowany jest z wykorzystaniem równoległej procedury, w przypadku konfliktu zasobów w pierwszej kolejności zasoby są przydzielane do czynności o większej wartości priorytetu. Wall (1996) zajmuje się problemem optymalizacji harmonogramu RCPS ze względu na kryterium terminu zakończenia projektu. Rozwiązanie tworzy na podstawie listy opóźnień względem najpóźniej zakończonego poprzednika. Hartmann (1997) przedstawia możliwość zastosowania GA dla rozwiązania problemu RCPS. Badaniem objęte zostały trzy rodzaje reprezentacji: (1) permutacyjna, (2) wartości priorytetu oraz (3) reguł priorytetu. Dla każdego rodzaju zastosowano wybrane rodzaje operatorów rekombinacji osobników. Hartmann zajmuje się optymalizacją harmonogramu ze względu na kryterium czasu zakończenia projektu. Hartmann (2001) rozszerza reprezentację permutacyjną na problem z alternatywnymi sposobami wykonania czynności dodatkowo wprowadzając procedury poprawy rozwiązania. Özdamar (1999) porównuje skuteczność działania hybrydowego GA opartego na reprezentacji w postaci reguł priorytetu oraz GA z reprezentacją permutacyjną w warunkach RCPS z wieloma sposobami wykonania czynności. Autorka wykazuje wyższość zaprojektowanego przez siebie algorytmu hybrydowego nad permutacyjnym GA, zauważając jednak ograniczony zakres zastosowania algorytmu hybrydowego z uwagi na silne związanie jego konstrukcji z typem zadania oraz nieznaczne zwiększenie czasu obliczeń. Ulusoy, Sivrikaya-Şerifoğlu i Şahin (2001) analizują możliwość zastosowania

GA z reprezentacją permutacyjną w rozwiązywaniu problemów RCPS z przepływami pieniężnymi i czterema różnymi modelami płatności. W analizie wykazują wyższość GA na procedurę LCBA. Alcaraz i Maroto (2001) do reprezentacji permutacyjnej wprowadzają dodatkowo oznaczenie sposobu budowy harmonogramu *wprzód* lub *wstecz* (ang. *forward/backward scheduling*) oraz proponują specjalnie zaprojektowane operatory krzyżowania dla tego rodzaju reprezentacji. Hindi, Yang i Fleszar (2002) prezentują algorytm określony mianem EA dla rozwiązania problemu klasy RCPS. W istocie jest to GA z reprezentacją permutacyjną, który wykorzystuje techniki opisane w pracy (Hartmann, 1997). Leu i Hung (2002) łączą GA z modelem symulacyjnym w procedurę optymalizacji harmonogramu realizacji projektów budowlanych. Ranjbar i Kianfar (2007) proponują zastosowanie GA do rozwiązania problemu RCPS z dyskretną zależnością czas-zasób. Dodatkowo dla poprawy skuteczności na etapie eksploatacji proponują wprowadzenie procedury poszukiwania lokalnego po mutacji osobników, podobnie jak Shadrokh i Kianfar (2007) dla problemu RIP (ang. *Resource Investment Problem*) z karą za opóźnienie. Podobnie Najafi i Niaki (2006) przedstawiają GA dla problemu RIP z ukierunkowaniem na maksymalizację zdyskontowanych przepływów pieniężnych. Debels i Vanhoucke (2005) przedstawiają algorytm genetyczny pracujący równolegle na dwóch populacjach harmonogramów, z których jedna to harmonogramy w najwcześniejszych terminach realizacji (ang. *left-shifted, forward schedule*), a druga to harmonogramy w najpóźniejszych terminach realizacji (ang. *right-shifted, backward schedule*), w odróżnieniu od np. Alcaraz i Maroto (2001), którzy sposób budowy włączają jako element reprezentacji.

Przeszukiwanie rozproszone

Yamashita, Armentano i Laguna (2003) przedstawiają algorytm SS dla problemu harmonogramowania projektu z kosztami wykorzystania zasobów i narzuconym terminem realizacji, który sformułował Möhring (1984) dla potrzeb projektu budowy mostu. Kierunkiem optymalizacji jest minimalizacja kosztów całkowitych zaangażowania zasobów. Rozwiązanie jest kodowane w postaci ciągu liczb naturalnych (z których każda odpowiada przyjętej liczebności zasobu), którego rozmiar równy jest liczbie zasobów wykorzystywanych w projekcie. Ten rodzaj kodowania nie może znaleźć zastosowania w klasycznym problemie RCPS. Bardziej obiecujący jest sposób kodowania, który opisują Campos, Laguna i Martí (2003) dla problemów permutacyjnych.

Algorytmy kolonii mrówek

Algorytmy kolonii mrówek (ang. ACO – *Ant Colony Optimization*) stanowią grupę metaheurystyk inspirowanych obserwacją zachowań społecznych mrówek poszukujących najkrótszej drogi do pożywienia (Bonabeau i in., 2000). Mrówka wędrując po ścieżce pozostawia substancję zwaną feromonem. Kolejne wędrujące mrówki przy wyborze drogi kierują się ilością feromonu na niej umieszczonego. Im szybciej mrówka powróci do kolonii tym szybciej zwiększy się ilość substancji na ścieżce. Ponieważ feromon paruje z czasem większość mrówek preferuje najkrótszą (najczęściej odwiedzaną) drogę. Opis ACO przedstawiają m.in. Colorni, Dorigo, Maffioli, Maniezzo, Righini i Trubian (1996), Dorigo, DiCaro i Gambardella (1999), Dorigo i Stützle (2002). Pierwszą wersję stanowił system mrówkowy (ang. AS – *Ant System*) stosowany w rozwiązaniu niewielkich rozmiarów zadań z zakresu optymalizacji kombinatorycznej. Kolejno AS był rozbudowywany poprzez wprowadzenie strategii elitarniej pozwalającej tylko najlepszemu (w iteracji lub w dotychczasowym procesie poszukiwania) osobnikowi aktualizację ścieżek feromonowych (Dorigo, Maniezzo i Colorni (1996)) co pozwala zintensyfikować poszukiwania. Bullnheimer, Hartl i Strauss (1999) zaproponowali rozwinięcie strategii elitarniej pozwalając określonej liczbie mrówek reprezentujących najkrótsze ścieżki aktualizację ścieżek feromonowych. Stützle i Hoos (2000) proponują MMAS (ang. *MIN-MAX Ant System*) wprowadzając ograniczenie górne i dolne dopuszczalnej wartości śladu feromonowego dla uniknięcia rozwiązań lokalnie optymalnych.

Merkle, Middendorf i Schneck (2000) przedstawiają algorytm ACO dla problemu RCPS z minimalizacją czasu trwania realizacji projektu. Ślad feromonowy zapisywany jest w macierzy kwadratowej o rozmiarze odpowiadającym liczbie czynności do umieszczenia w harmonogramie. Indeksy wierszy macierzy odpowiadają oznaczeniom czynności do uszeregowania, natomiast indeksy kolumn odpowiadają pozycji, na

której czynność znajduje się w uszeregowaniu. Osobnik tworzy uszeregowanie na podstawie wcześniejszego zapisu śladu feromonowego wybierając kolejne czynności w sposób losowy proporcjonalnie do sumy ważonej ilości feromonu odpowiadającego umieszczeniu go na pozycjach od 1 do obecnie bieżącej – reprezentacja sumacyjna (ang. *summation evaluation*), którą wprowadzili Merkle i Middendorf (2000) oraz feromonu na pozycji bieżącej – reprezentacja bezpośrednia (ang. *direct evaluation*). Po zakończeniu cyklu osobnik aktualizuje ślad zwiększając ilość feromonu w elementach odpowiadających czynnościom i pozycjom, na których są one umieszczone. Feromon pozostawia najlepszy osobnik w danym cyklu oraz najlepszy dotychczas odnaleziony osobnik.

Algorytm roju cząsteczek

Kennedy i Eberhart (1995) przedstawiają nowy rodzaj metaheurystyki oparty podobnie jak ACO o ideę inteligencję roju (ang. *swarm intelligence*) – algorytm roju cząsteczek (ang. PSO – *Particle Swarm Optimization*). Zhang, Li i Tam (2006a,b) przedstawiają zastosowanie PSO z reprezentacją wartości priorytetu do rozwiązania problemu RCPS w obszarze projektów budowlanych według kryterium minimalizacji czasu zakończenia projektu. Zhang i Tam (2006) opisują rozszerzenie PSO w wersji dla wielo-modalnych problemów RCPS.

2.7 Podsumowanie

W ramach analizy stanu badań w zakresie harmonogramowania przedstawiono: podstawowy zakres pojęć z zakresu zarządzania projektami i harmonogramowania, klasyfikację harmonogramów, przegląd sieciowych metod zapisu problemu harmonogramowania, klasyfikację problemów ze względu na obszar decyzyjny i rodzaj ograniczeń ujętych w modelu. Na końcu przedstawiono przegląd metod dokładnych, heurystycznych oraz metaheurystycznych stosowanych w obszarze harmonogramowania projektów. Problematyka harmonogramowania przedsięwzięć stanowi najbardziej złożony obszar spośród modeli harmonogramowania ze względu na różnorodność samego zjawiska zarządzania projektami. Zaobserwowano liczne zastosowania heurystyk i metaheurystyk do rozwiązania problemów jedno-modalnych RCPS ze względu na kryteria czasowe. Mniej licznie reprezentowane są badania dotyczące optymalizacji wielo-modalnych problemów RCPS ze względu na kryteria czasowe. Jedynie w nielicznych badaniach pojawiają się modele z optymalizacją wielkości ekonomicznych w środowisku wielo-modalnym (Ulusoy, Sivrikaya-Şerifoğlu i Şahin (2001) bez ograniczeń czasowych, Mika, Waligóra i Węglarz (2005) dla dodatnich wartości przepływów pieniężnych, Bouleimen i Lecocq (2003), Józefowska, Mika, Różycki, Waligóra i Węglarz (2001) w zakresie \$A). Brak badań w obszarze zastosowania \$S, PLA, ACO w rozwiązywaniu problemów wielo-modalnych ze względu na kryteria pieniężne. Wśród heurystyk priorytetowych brak jest rozwiązań uwzględniających wielo-modalność, metody te opierają działanie wyłącznie na uszeregowaniu listy czynności w projekcie w ramach jednego sposobu ich realizacji. W badaniach stosowane są modele harmonogramowania przedsięwzięć uwzględniające uproszczenia w opisie zależności kolejnościowych, bezwzględnych ograniczeń czasowych oraz przede wszystkim w ujęciu parametrów ekonomicznych: od strony kosztów (wydatków) i przychodów (wpływów). W większości badań kwestie ekonomiczne nie stanowią istotnej kwestii badawczej i może to spowodować pominięcie specyficznych aspektów związanych ze skutkami decyzji podejmowanych na etapie harmonogramowania właściwych dla realiów zarządzania projektem. W trakcie konstruowania modelu harmonogramowania należy zwrócić uwagę na możliwie szerokie i elastyczne modelowanie przepływów pieniężnych związanych z realizacją prac.

Ekonomiczne aspekty harmonogramowania projektów


Dla kompleksowej oceny skutków realizacji projektu konieczna jest jego ewaluacja z uwzględnieniem czynników ekonomicznych. W literaturze spotykane jest często podejście sekwencyjne, w którym pierwszy etap stanowi opracowanie harmonogramu, a dopiero po podjęciu decyzji o terminach realizacji prac określone są skutki ekonomiczne (Dixon, 2000, Maylor, 2003). W niniejszym rozdziale przedstawiono metody oceny skutków ekonomicznych decyzji związanych z planowaniem przebiegu projektu. Przedstawiono czynniki ekonomiczne mające główny wpływ na ocenę skutków harmonogramu projektu oraz stosowane metody oceny działalności inwestycyjnej, które w efekcie powinny pozwolić na zastosowanie właściwych kryteriów dla oceny jakości procesu budowy harmonogramu.

3.1 Koszty realizacji projektów

Realizacja projektu związana jest z koniecznością poniesienia określonych kosztów. Zwykle w literaturze z zakresu zarządzania projektami przyjmuje się, że koszty realizacji projektu można podzielić na następujące grupy (Maylor, 2003):

- koszty pracy – zawierające wynagrodzenie pracowników bezpośrednio realizujących projekt oraz koszt pracy sprzętu własnego i obcego,
- koszty materiałów – koszty wszelkiego rodzaju materiałów zużywanych wraz z realizacją projektu,
- koszty dodatkowe – obejmujące m. in. koszty transportu, szkoleń,
- koszty ogólne – obejmujące koszty obsługi organizacji, opłaty za biura, usługi finansowe, wynagrodzenia kierowników i innych osób nie zaangażowanych bezpośrednio w realizację projektu.

Dwie pierwsze grupy stanowią koszty bezpośrednie projektu, natomiast pozostałe określane są mianem kosztów pośrednich. Istnieje możliwość modelowania kosztów realizacji projektu poprzez strukturę kosztów *CBS - cost breakdown structure*, opartą na metodzie struktury prac *WBS – work breakdown structure*. Polega ona na opisanu struktury kosztów realizacji projektu zgodnie z podziałem rodzajowym. Trocki, Grucza i Ogonek (2003) analizują koszty projektu – związane z poszczególnymi fazami realizacji projektu – przedstawiając model cyklu życia projektu z uwzględnieniem informacji o poziomie kosztów. Autorzy dzielą realizację projektu na: (1) fazę definiowania projektu charakteryzującą się niewielkimi, wolno rosnącymi kosztami, (2) fazę planowania i organizowania wykonawstwa projektu w której koszty są na poziomie średnim i rosną, (3) fazę wykonawstwa, w której koszty są wysokie i rosną do maksymalnego poziomu oraz (4) fazę zakończenia projektu, gdzie koszty są na średnim poziomie i maleją. Dodatkowo wyróżniono dwa zasadnicze rodzaje kosztów: (1) k. działalności kierowniczej oraz (2) k. działalności wykonawczej. Koszty w modelu cyklu życia projektu przedstawiono na rys. 3.1. Autorzy podkreślają, że największe nasilenie kosztów następuje w fazie wykonawstwa, której szczególnie dotyczy problem harmonogramowania prac i skutków ekonomicznych z tym związanych.



Rys. 3.1: Koszty w modelu cyklu życia projektu (Trocki i in., 2003, s. 32)

3.2 Modele realizacji płatności

W przypadku organizacji zarządzanych przez projekty dostarczających dobra lub usługi istotnym elementem kształtującym efekt ekonomiczny poza kosztami jest sposób uzyskiwania wpływów z tytułu prowadzonej działalności. Sposoby uzyskiwania wpływów określane są zwykle w tego rodzaju działalności poprzez ustalenia umowne (kontraktowe) w zakresie momentu i wielkości realizacji płatności za wykonane prace lub efekty. Na etapie organizowania i planowania wykonawstwa projektu kwestia wielkości i sposobu zrealizowania płatności staje się przedmiotem negocjacji pomiędzy klientem (w tym przypadku zwanym zazwyczaj inwestorem), a producentem (czyli wykonawcą).

W praktyce funkcjonuje duże zróżnicowanie w zakresie metod określania wartości kontraktu. Zasadniczo można wyróżnić dwie grupy: (1) kontrakty o cenie stałej i (2) kontrakty o cenie zmiennej. W pierwszym przypadku kwota, jaką zobowiązany jest zapłacić inwestor jest znana i określona przed fazą wykonawczą projektu. W przypadku kontraktów o cenie zmiennej kwota określana jest w zależności od kosztów realizacji projektu. Kwota kontraktu składa się z dwóch składników: kosztów oraz opłaty dla wykonawcy (zawierającej zysk). Istnieje duże zróżnicowanie sposobów określania kwot kontraktu (będące odzwierciedleniem samego zróżnicowania projektów) – w praktyce najpowszechniejsze są:


- koszt + procent kosztów – kwotę kontraktu stanowią koszty realizacji projektu powiększone o marżę określoną jako procent poniesionych kosztów. W przypadku gdy koszty projektu wzrosną, wzrasta również wysokość opłaty. Do wad tego rodzaju kontraktów po stronie inwestora należy zaliczyć: (1) brak zachęty do szybkiego ukończenia prac, (2) wzrost kwoty kontraktu wraz ze wzrostem kosztów oraz (3) brak znajomości ceny przed ukończeniem fazy wykonawczej projektu.
- koszt + stała opłata – kwotę kontraktu stanowią koszty powiększone o stałą kwotę określaną zwykle jako procent od szacunku kosztów. W przypadku, gdy wzrastają koszty realizacji projektu, opłata pozostaje stała na określonym w kontrakcie poziomie. Do zalet po stronie inwestora można zaliczyć: (1) stałość kwoty niezależnie od zmian cen oraz (2) zachętę do szybkiego zrealizowania prac. Główne ryzyko po stronie wykonawcy stanowi możliwość znacznego wzrostu kosztów w trakcie realizacji i zanik zysku.
- koszt + stała opłata + klauzula podziału zysku – w tym przypadku ustalana jest maksymalna gwarantowana cena, którą zapłaci inwestor. Klauzula podziału określa jaką część zysku (rozumianego

jako cena gwarantowana pomniejszona o koszty realizacji) jest należna wykonawcy, pozostała część stanowi własność inwestora. Główną zaletą po stronie inwestora jest mobilizacja wykonawcy do oszczędnej realizacji projektu. Natomiast zasadniczą wadą dla wykonawcy jest konieczność poniesienia wszelkich kosztów przekraczających gwarantowaną cenę maksymalną. Pewną trudność stanowi konieczność przygotowania szczegółowych planów i specyfikacji obiektu.

Kolejną istotną kwestią jest sposób realizowania płatności. Z punktu widzenia klienta najbardziej opłacalną sytuacją jest realizacja płatności po zakończeniu realizacji projektu, natomiast wykonawca zainteresowany jest uzyskaniem płatności wraz z rozpoczęciem projektu. W literaturze można spotkać następujące modele realizacji płatności w przedsięwzięciach projektowych (Mika i in., 2005, Ulusoy i in., 2001):

- **w całości po zakończeniu** (ang. LSP – *Lump Sum Payment*) – wykonawca jest zobowiązany sfinansować samodzielnie wszelkie koszty realizacji projektu do czasu jego zakończenia. Tego rodzaju forma realizacji płatności wymaga od wykonawcy zabezpieczenia kapitału na poczet realizacji projektu i w praktyce możliwe jest finansowanie w ten sposób jedynie niewielkich projektów. Po zakończeniu projektu inwestor wypłaca całą uzgodnioną kwotę kontraktu.
- **przy zdarzeniach** (ang. PEO – *Payments at Event Occurrences*) – płatności za projekt realizowane są po zakończeniu określonych prac (zwykle przy kamieniach milowych). Wielkość płatności uzależniona jest od zakresu ukończonych prac. Ostatnia wypłata następuje po zakończeniu całego projektu. Rozłożenie wypłat w czasie pozwala zmniejszyć obciążenie kapitałowe po stronie wykonawcy.
- **w określonych odstępach czasu** (ang. ETI – *Equal Time Intervals*) – klient zobowiązany jest zrealizować H płatności za projekt, z czego $(H - 1)$ rat w ustalonych z góry stałych interwałach czasowych. Ostatnia rata wypłacana jest po zakończeniu całego projektu.
- **w równych odstępach czasu** (ang. PP – *Progress Payments*) – płatności realizowane są w stałych interwałach czasowych, aż do zakończenia projektu. W odróżnieniu od ETI nie jest znana z góry liczba rat, ponieważ jest ona zależna od czasu realizacji projektu. Co stały okres czasu inwestor na podstawie kosztów poniesionych przez wykonawcę w ostatnim okresie rozliczeniowym dokonuje wypłaty określonej na tej podstawie kwoty (np. powiększonej o marżę w przypadku kontraktu koszt + procent kosztów).

Realizacja płatności w formie ratalnej (PEO, ETI, PP) pozwala wykonawcy zmniejszyć zamrożenie kapitału z tytułu realizacji projektu. Celem inwestora jest zwykle ograniczenie płatności do pokrycia poniesionych już wydatków. Na rys. 3.2 przedstawiono przepływ gotówki dla różnych modeli płatności w ramach przykładowego projektu. Niezbilansowana wartość skumulowanych przepływów pieniężnych NCF wskazuje na poziom zamrożenia kapitału, który będzie musiał zabezpieczyć wykonawca. Poziom ten wzrasta wraz ze zmniejszeniem liczby płatności za projekt, osiągając w przypadku modelu LSP wartość równą całości kosztów realizacji projektu.



Rys. 3.2: Porównanie przepływów pieniężnych i efektywności dla wybranych rodzajów modeli płatności: (a) dla równych odstępów czasu 1-miesięcznych, (b) dla równych odstępów czasu 3-miesięcznych oraz (c) w całości po zakończeniu. W każdym przypadku $P = 815,10$ [j.p.] oraz $K = 741,00$ [j.p.]. Wpływy otrzymywane są zgodnie z modelem w miesiącu następnym po poniesieniu wydatków.

3.3 Płynność finansowa projektu

Płynność finansowa definiowana jest jako zdolność przedsiębiorstwa do wywiązywania się z krótkoterminowych zobowiązań - to znaczy tych, które są płatne w przeciągu jednego roku.

Oceny płynności finansowej można dokonać na podstawie sprawozdań finansowych (Sierpińska i Wędzki, 2001):

- w **ujęciu statycznym** (analiza zasobów) w odniesieniu do konkretnego momentu, np. do dnia bilansowego, wykorzystując podstawowe sprawozdania finansowe: bilans i rachunek zysków i strat oraz tradycyjne wskaźniki płynności finansowej,
- w **ujęciu dynamicznym** (analiza strumieni) w odniesieniu do okresu czasu, w oparciu o sprawozdanie z przepływów pieniężnych (ukazujące uzyskane i wydatkowane środki pieniężne) i sprawozdanie z przepływu kapitałów (prezentujące źródła pochodzenia i sposoby wykorzystania kapitału obrotowego).

Pomiaru poziomu płynności w sposób statyczny można dokonać za pomocą wskaźników (Bednarski, 1994, Manikowski i Tarapata, 2001):

- wskaźnik płynności finansowej pierwszego stopnia (płynność bieżąca): relacja środków obrotowych (aktywów bieżących) ogółem do zobowiązań bieżących. Wartość wskaźnika powinna należeć do przedziału (1,5; 2,0).
- wskaźnik płynności finansowej drugiego stopnia (szybka płynność, płynność przyspieszona): relacja sumy środków pieniężnych, należności i krótkoterminowych papierów wartościowych do zobowiązań bieżących. Wartość wskaźnika powinna być równa około 1.
- wskaźnik płynności finansowej trzeciego stopnia (płynność gotówkowa, płynność pieniężna): relacja środków pieniężnych (lub środków pieniężnych powiększonych o papiery wartościowe do obrotu) do zobowiązań bieżących. Określa zdolność przedsiębiorstwa do natychmiastowej realizacji zobowiązań bieżących. Wartość wskaźnika powinna mieścić się w przedziale (0,1; 0,2).

W praktyce zalecane poziomy wskaźników stanowią jedynie ogólną wskazówkę do zarządzania płynnością i potrzebne są indywidualne rozwiązania (zarówno w zakresie konstrukcji, jak i zalecanych poziomów) dla każdej organizacji uwzględniające jej specyficzny charakter¹.

Działalność projektowa (zwłaszcza inwestycyjna) podatna jest na ryzyko utraty płynności (Ostrowska, 2002). Harmonogram realizacji projektu wyznaczając terminy realizacji czynności wyznacza jednocześnie terminy wydatków i wpływów związanych z ich realizacją (przyjmując terminowe realizowanie zobowiązań). Uwzględniając w procesie harmonogramowania informacje o związanych z realizacją czynności przepływach pieniężnych, można uwzględnić je jako ograniczenie lub kierunek optymalizacji. W przypadku uznania dostępnych środków pieniężnych jako ograniczenia – utrzymanie płynności oznaczać będzie utrzymanie dodatnich skumulowanych sald pieniądza w całym okresie trwania projektu, natomiast w przypadku uznania płynności jako kryterium oceny – celem może być zrównoważenie zapotrzebowania na środki pieniężne w trakcie realizacji projektu lub minimalizacja zamrożenia środków własnych (kryteria te nie muszą być równoważne).

3.4 Metody oceny efektywności ekonomicznej projektów

Przedmiot niniejszej pracy stanowią przedsięwzięcia o deterministycznych wielkościach przepływów pieniężnych związanych z realizacją. Ocena *opłacalności* projektu można przeprowadzić w oparciu o metody statyczne (proste) - zakładające stałą wartość pieniądza w czasie, bądź w oparciu o metody dynamiczne

¹Sierpińska i Wędzki (2001) przedstawiają przykład wpływu specyfiki branży na poziom wskaźników na s. 60.

(dyskontowe) uwzględniające zmianę wartości pieniądza w czasie. Poniżej przedstawiono krótki przegląd metod oceny efektywności ekonomicznej przedsięwzięć (w tym inwestycyjnych)².

3.4.1 Statyczne metody oceny

Ponieważ przedmiotem pracy jest ocena skutków ekonomicznych decyzji podejmowanych na etapie budowy (optymalizacji) harmonogramu realizacji projektu nie ma możliwości zastosowania tu metod związanych bezpośrednio z oceną efektywności ekonomicznej projektów inwestycyjnych³. Wśród statycznych metod oceny efektywności ekonomicznej projektów inwestycyjnych Manikowski i Tarapata (2001) wyróżniają: (1) metodę porównania kosztów, (2) metodę porównania zysków, (3) metodę porównania rentowności oraz (4) metodę okresu zwrotu nakładów. W przypadku analizy realizacji projektu spośród kryteriów statycznych pozostaje: zyskowość lub rentowność projektu oraz okres zwrotu. Analiza porównania kosztów ma zastosowanie we wstępnej ocenie projektów i koncentruje się ona na możliwości obniżenia kosztów jednostkowych produkcji, pomijając warunki zewnętrzne. Metoda porównania zysków opiera się na różnicy przychodów (P) i kosztów (K) z inwestycji. Kryterium wyboru jest wartość zysku ($Z = P - K$), a kierunkiem optymalizacji maksymalizacja wartości kryterium (wartości kryterium $Z \leq 0$ dyskwalifikują projekt jako nieopłacalny). Kryterium rentowności polega na porównaniu wartości zysku z inwestycji do wielkości zaangażowanych kapitałów⁴. Podobnie jak w przypadku zyskowości, kierunkiem optymalizacji jest maksymalizacja wartości kryterium i wielkości mniejsze od 0 kwalifikują projekt jako nierentowny.

Dodatkowo oceniając harmonogram projektu na podstawie związanych z jego realizacją wielkości przepływów pieniężnych kryterium zyskowości sprowadza się do różnicy pomiędzy wpływami i wydatkami. Podstawową wadą takiego podejścia jest pomijanie istotnych informacji o terminach wystąpienia przepływów.

3.4.2 Dynamiczne metody oceny

Z uwagi na zmienną wartość pieniądza w czasie, która wynika z różnej płynności pieniądza będącego w dyspozycji obecnie i pieniądza, który zostanie uzyskany w przyszłości czyli m. in. z (Manikowski i Tarapata, 2001, Rogowski, 2004):

- bieżącej konsumpcji – większość społeczeństw preferuje bieżącą konsumpcję od przesuniętej w czasie na wyższym poziomie,
- możliwości inwestycji – zainwestowana kwota może być powiększona w przyszłości,
- wpływu ryzyka – im większe ryzyko inwestycji tym oczekuje się, że stopa zwrotu będzie większa niż w przypadku inwestycji o mniejszym ryzyku.

Uzależniony od upływu czasu spadek wartości pieniądza sprawia, że porównanie następujących po sobie wpływów i wydatków realizowanych przez przedsiębiorstwo możliwe jest dopiero po odpowiednim ich przeliczeniu. Dla porównania i oceny różnych strumieni pieniężnych stosuje się metody opierające się na **dyskontowaniu** (ang. *discounting*), czyli obliczaniu wartości obecnej przyszłych przepływów pieniężnych. Pozwalają one na sumowanie (odejmowanie) wpływów i wydatków pojawiających się w różnych momentach czasu. Wartość obecna przyszłej płatności gotówkowej jest zawsze mniejsza od wartości nominalnej, a

²Szczegółowe omówienie prezentowanych metod i wskaźników oceny opłacalności i efektywności ekonomicznej inwestycji i przedsięwzięć przedstawiają m. in.: Jajuga i Jajuga (2006), Manikowski i Tarapata (2001), Nowak, Pielichaty i Poszwa (1999), Rogowski (2004), Stabryła (2006).

³Proste metody oceny inwestycji rzeczowych (prosta stopa zwrotu, przeciętna stopa zwrotu, okres zwrotu) zakładają poniesienie określonych wydatków w celu uzyskania w przeszłości cyklicznie występujących przychodów. Optymalizacja harmonogramu realizacji projektu w niniejszej pracy skupia się na harmonogramowaniu fazy wykonawczej projektu, która zwykle nie spełnia przedstawionego założenia.

⁴W praktyce spotykane są różne definicje kryterium rentowności: rentowność sprzedaży, rentowność netto, rentowność brutto, EBIT, EBITDA. Wszystkie one sprowadzają się do przyrównania różnie sformułowanego zysku (przed opodatkowaniem, po opodatkowaniu, bez amortyzacji, itp.) do wielkości przychodów lub nakładów.

do jej obliczenia wymagane jest zdyskontowanie wartości nominalnej. W praktyce stosuje się dwa rodzaje czynników: (1) cz. oprocentowujący – wynoszący $(1 + d)^t$ w okresie t przy stopie procentowej d oraz (2) cz. dyskontujący stanowiący odwrotność czynnika oprocentowującego. W związku z tym, **wartość przyszła** (ang. *FV - Future Value*) strumienia $(x_0, x_1, x_2, \dots, x_n)$ przepływów pieniężnych, oprocentowanych w każdym okresie według stopy procentowej d , jest równa:

$$FV = x_0(1 + d)^n + x_1(1 + d)^{n-1} + x_2(1 + d)^{n-2} + \dots + x_n \quad (3.1)$$

I podobnie **wartość obecna** (ang. *PV - Present Value*) strumienia $(x_0, x_1, x_2, \dots, x_n)$ przepływów pieniężnych, oprocentowanych w każdym okresie według stopy procentowej d , jest równa:

$$PV = x_0 + \frac{x_1}{1 + d} + \frac{x_2}{(1 + d)^2} + \dots + \frac{x_n}{(1 + d)^n} \quad (3.2)$$

Istotną kwestią w metodach dynamicznych jest właściwy wybór stopy dyskontowej d . Najczęściej stopa dyskontowa definiowana jest jako (Rogowski, 2004):

- minimalna stopa zwrotu z przedsięwzięcia inwestycyjnego, która musi być osiągnięta, aby w wyniku realizacji ocenianego przedsięwzięcia inwestycyjnego wartość rynkowa firmy nie spadła,
- stopa zwrotu, jaką można uzyskać na rynku kapitałowym, inwestując w inne inwestycje o poziomie ryzyka zbliżonym do ryzyka ocenianego projektu,
- koszt kapitału firmy, niezbędny do sfinansowania przedsięwzięcia o danym poziomie ryzyka.

Najpowszechniejszym sposobem określania stopy dyskontowej jest ustalenie jej na poziomie średniego ważonego kosztu kapitału (ang. *WACC - Weighted Avaraged Cost of Capital*), który można rozumieć jako stopę procentową dającą inwestorom korzyści co najmniej takie, jakie występują przeciętnie na rynku (Stabryła, 2006). **Wartość zaktualizowana netto**⁵ (ang. *NPV - Net Present Value*) stanowi najpowszechniej używane kryterium oceny efektywności ekonomicznej projektów o charakterze inwestycyjnym. *NPV* obliczane jest jako wartość obecna ze strumienia sald pieniężnych netto lub jako różnica wartości bieżącej strumienia wpływów $(i_0, i_1, i_2, \dots, i_n)$ i wartości bieżącej strumienia wydatków $(e_0, e_1, e_2, \dots, e_n)$ z okresu od chwili bieżącej ($t = 0$) do horyzontu planowania (T).

$$NPV = \sum_{t=0}^T \frac{i_t}{(1 + d)^t} - \sum_{t=0}^T \frac{e_t}{(1 + d)^t} = \sum_{t=0}^T \frac{i_t - e_t}{(1 + d)^t} \quad (3.3)$$

W przypadku, gdy $NPV > 0$ przedsięwzięcie jest opłacalne, dla $NPV = 0$ przedsięwzięcie jest neutralne oraz w przypadku gdy $NPV < 0$ przedsięwzięcie jest nieopłacalne.

Wewnętrzna stopa zwrotu (ang. *IRR - Internal Rate of Return*) jest tą wielkością stopy dyskontowej d , przy której wartość obecna strumienia przepływów pieniężnych $(x_0, x_1, x_2, \dots, x_n)$ jest równa 0:

$$IRR = r \Leftrightarrow 0 = x_0 + \frac{x_1}{1 + r} + \frac{x_2}{(1 + r)^2} + \dots + \frac{x_n}{(1 + r)^n} \quad (3.4)$$

IRR może być interpretowane jako: graniczna koszt kapitału lub jako pieniężna stopa zwrotu z zainwestowanego kapitału. Kryterium decyzyjnym w przypadku *IRR* jest: $IRR > d$ - przedsięwzięcie jest opłacalne, $IRR = d$ - przedsięwzięcie jest neutralne oraz $IRR < d$ - inwestycja jest nieopłacalna. Metoda *IRR* wymaga, aby wielkości przepływów $(x_0, x_1, x_2, \dots, x_n)$ spełniały warunki: $x_0 < 0$ i $x_k \geq 0$ dla każdego $k = 1, 2, \dots, n$. W przypadku oceny harmonogramów projektów nie można zapewnić spełnienia tego warunku w każdym przypadku⁶. Ponadto kryterium *IRR* jest zgodne z kryterium *NPV* w przypadku oceny jednego projektu, czy harmonogramu. Sprzeczność może pojawiać się w przypadku oceny

⁵W literaturze występują zamiennie określenia: tężniejsza wartość netto, wartość kapitałowa inwestycji, aktualna wartość nadwyżki netto, aktualna wartość nadwyżki finansowej netto, aktualna wartość netto, wartość bieżąca netto.

⁶Rogowski (2004) przedstawia przykład profilu *NPV* dla nietypowego przedsięwzięcia inwestycyjnego z dwoma wartościami *IRR* (s. 132)

projektów różniących się czasem trwania⁷. Natomiast w przypadku konieczności porównania różnych wariantów projektów o odmiennych wielkościach zaangażowanego kapitału formuła NPV może stać się również niewystarczająca. W takich przypadkach stosowany bywa **wskaźnik wartości zaktualizowanej netto** (ang. $NPVR$ - *Net Present Value Ratio*) wyrażone jako:

$$NPVR = \frac{NPV}{\sum_{t=0}^T i_t} \quad (3.5)$$

Bezwzględne kryterium oceny w przypadku $NPVR$ jest identyczne jak dla NPV , natomiast w przypadku porównania różnych projektów względnym kryterium decyzyjnym staje się maksymalizacja wartości $NPVR$. Podobne podejście można odnaleźć we **wskaźniku rentowności** (ang. PI - *Profitability Index*), gdzie w liczniku pozostaje jedynie bieżąca wartość wpływów, natomiast mianownik pozostaje bez zmian:

$$PI = \frac{\sum_{t=0}^T \frac{e_t}{(1+d)^t}}{\sum_{t=0}^T \frac{i_t}{(1+d)^t}} \quad (3.6)$$


Interpretacja ekonomiczna metody wskaźnika rentowności mówi nam, ile jednostek wartości bieżącej dodatnich przepływów pieniężnych netto przypada na jedną jednostkę wartości bieżącej ujemnych przepływów pieniężnych lub nakładów inwestycyjnych (Rogowski, 2004). Bezwzględnym kryterium decyzyjnym jest: $PI > 1$ - inwestycja jest opłacalna, $PI = 1$ inwestycja jest neutralna oraz $PI < 1$ inwestycja jest nieopłacalna. Jednym z założeń IRR trudnym do spełnienia w rzeczywistości jest możliwość reinwestowania nadwyżek pieniężnych według stopy IRR . Wskaźnikiem pozbawionym tej niedogodności jest **zmodyfikowana wewnętrzna stopa zwrotu** (ang. $MIRR$ - *Modified Internal Rate of Return*) zdefiniowana jako:

$$MIRR = \sqrt[n]{\frac{\sum_{t=0}^T e_t * (1+d)^{t-1}}{\sum_{t=0}^T \frac{i_t}{(1+d)^t}}} - 1 \quad (3.7)$$


Zasady wyboru w przypadku $MIRR$ są takie same jak w przypadku IRR . Wartość $MIRR > d$ pozwala przyjąć inwestycję jako opłacalną, $MIRR = d$ oznacza neutralność efektów, natomiast $MIRR < d$ wskazuje na brak opłacalności przedsięwzięcia.

Wszystkie powyższe argumenty wskazują, że dla oceny jakości harmonogramu projektu najwłaściwszym kryterium jest maksymalizacja wartości bieżącej przepływów pieniężnych związanych z realizacją. Ponieważ nie możliwości zapewnienia spełnienia warunków $x_0 < 0$ i $x_k \geq 0$ dla każdego $k = 1, 2, \dots, n$ dla obliczenia wewnętrznej stopy zwrotu, NPV pozostaje najlepszym kryterium dynamicznym, które może znaleźć zastosowanie w optymalizacji harmonogramów niezależnie od profilu przepływów pieniężnych. Z drugiej strony kryteria statyczne nie pozwalają odzwierciedlić w sposób kompletny skutków decyzji właśnie na etapie optymalizacji harmonogramu poprzez zrównanie momentu wystąpienia płaćności i wydatków, które to momenty zależne są wprost od decyzji podjętych na etapie konstrukcji harmonogramu. Zauważyć należy, że w przypadku modeli z wieloma sposobami wykonania czynności kryteria statyczne są w stanie rozróżniać i oceniać rozwiązania w przestrzeni sposobów wykonania, nie są natomiast zdolne rozróżniać rozwiązań w zależności od terminów realizacji czynności. Na rys. 3.2 przedstawiono przepływ gotówki dla różnych modeli płaćności w ramach przykładowego projektu. Dodatkowo na wykresach zaznaczono w ramce wartość NPV obliczoną dla stopy dyskontowej $d = 0,5\%$ oraz wartość IRR . Zachowując stałe kwoty i terminy realizacji poniesionych kosztów i przychodów efektywność ekonomiczna wykonania zmienia się z $IRR = 10\%$ dla 1-miesięcznych PP do $IRR = 1,7\%$ przy LSP. Podobne zmiany NPV można

⁷przykłady tego rodzaju przedstawiono w (Sierpińska i Jachna, 1993) s. 226, (Luenberger, 2003) s. 46, (Jajuga i Jajuga, 2006) s. 350



Rys. 3.3: Proces budowy harmonogramu bez uwzględnienie czynników ekonomicznych (Maylor, 2003, s. 122)



Rys. 3.4: Zmodyfikowany proces budowy harmonogramu

zaobserwować dla zmian terminów realizacji w ramach harmonogramu zachowując wszelkie wartości kosztów i przychodów (nie zmieniając samego sposobu wykonania czynności, a jedynie kolejność ich realizacji).

3.5 Zastosowanie oceny efektywności ekonomicznej w harmonogramowaniu

Zastosowanie postulatu ekonomicznej oceny w procesie budowy i optymalizacji harmonogramu wymaga odmiennego od powszechnie prezentowanego podejścia i zakresu danych. Na rys. 3.3 przedstawiono proces budowy harmonogramu (Dixon, 2000, Maylor, 2003), który jest zgodny z metodyką PM Institute. Informacje wejściowe do harmonogramowania obejmują tu informacje o strukturze projektu (zależności kolejnościowe, ograniczenia czasowe), informacje o zasobach i ich dostępności (kalendarze), oszacowania czasów trwania czynności. Efektem procedury budowy harmonogramu jest plan terminów rozpoczęcia i zakończenia czynności. Ocena skutków ekonomicznych podjętych decyzji następuje w kolejnych etapach organizowania fazy wykonawczej. Jest to wspólną cechą wielu prezentowanych w literaturze rozwiązań, a wynika wprost ze stosowania prostych metod budowy harmonogramu (CPM, PERT, MPM) pozbawionych możliwości optymalizacji. Prezentowane w niniejszej pracy podejście do procedury budowy i wartościowania harmonogramu wymaga rozszerzenia zakresu danych wejściowych o informacje o: (1) wydatkach (kosztach) związanych z realizacją czynności, (2) wydatkach (kosztach) związanych z użyciem zasobów oraz (3) wpływach związanych z zakończeniem realizacji czynności (zgodnie z modelem płatności). Dodatkowo efektem procedury harmonogramowania jest tu nie tylko plan realizacji prac ale również prognoza związanych z nim przepływów pieniężnych. Zmodyfikowany proces budowy harmonogramu przedstawiono na rys. 3.4.

3.6 Podsumowanie

Dla kompleksowej oceny skutków realizacji projektu według określonego harmonogramu konieczna jest jego ewaluacja w oparciu o wielkości ekonomiczne. Najpowszechniej stosowaną wielkością umożliwiającą ocenę i porównanie różnych wariantów realizacji przedsięwzięcia jest zysowność lub wartość zaktualizowana netto. W przypadku prostego kryterium zysowności harmonogram realizacji prac w obszarze kolejności czynności nie ma żadnego wpływu na uzyskaną wartość kryterium, jedynie wybór spośród sposobów wykonania czynności może wpływać na zmianę wartości kryterium. Kryterium dynamiczne *NPV* pozwala na uwzględnienie (wycenę) decyzji podejmowanych w zakresie kolejności realizacji czynności i zastosowanie tego kryterium w ocenie harmonogramu powinno pozwolić na właściwą ocenę jego jakości. Z drugiej strony wprowadzenie do modelu harmonogramowania informacji o dostępności środków pieniężnych (w formie ograniczeń lub kierunku optymalizacji) dla realizacji przedsięwzięcia pozwoli na ograniczenie ryzyka utraty płynności poprzez zapewnienie realizacji prac w ramach posiadanego kapitału (ograniczenia) lub wskazanie poziomu zapotrzebowania na kapitał (kierunek optymalizacji). Często w literaturze prezentowane jest podejście sekwencyjne, w którym najpierw budowany jest harmonogram projektu, a następnie na podstawie tegoż harmonogramu określone są koszty jego realizacji i dalej opracowywany jest budżet (Dixon, 2000). Podejście tego rodzaju wydaje się niewystarczające dla zapewnienia racjonalnego gospodarowania zasobami przedsiębiorstwa i rozszerzenie zakresu informacji o dane finansowe już na etapie budowy harmonogramu pozwoli na uzyskanie lepszych w wymiarze ekonomicznym efektów.

Model harmonogramowania projektów z uwzględnieniem czynników ekonomicznych

Niniejszy rozdział zawiera opis opracowanego dla potrzeb pracy modelu harmonogramowania realizacji projektów. Kolejno przedstawiono: założenia przyjęte przy konstrukcji modelu, opis struktury danych, sformułowanie ograniczeń, formalizację organizacyjnych i ekonomicznych kryteriów oceny dla modelu. Na zakończenie przedstawiono procedurę normalizacji problemu RCPS.

4.1 Model harmonogramowania projektów

4.1.1 Założenia modelu

Dla potrzeb weryfikacji hipotez sformułowanych w rozdziale 1, zbudowano model spełniający następujące założenia:

- ma charakter dyskretny i deterministyczny,
- obejmuje środowisko wielo-projektowe – z uwzględnieniem odrębności strukturalnej każdego projektu i wspólnego korzystania z zasobów,
- pozwala elastycznie definiować koszty i wpływy związane z realizacją poszczególnych projektów, czynności i użyciem zasobów,
- uwzględnia możliwość wykorzystywania zasobów odnawialnych, nieodnawialnych oraz podwójnie ograniczonych – z możliwością elastycznego określenia poziomu dostępności zasobu w różnych okresach czasu,
- uwzględnia wielo-modalność realizacji czynności – możliwe jest określenie wielu sposobów wykonania czynności różniących się czasem realizacji, zaangażowaniem zasobów i kosztem,
- możliwe jest elastyczne określenie względnych, jak i bezwzględnych ograniczeń czasowych.

Założenia te zawierają uwarunkowania występujące zarówno w środowisku jedno-projektowym, jak i w harmonogramowaniu realizacji wielu projektów jednocześnie. Założenia do modelu oparte są na analizie potrzeb w zakresie modelowania harmonogramu występujących w różnego rodzaju organizacjach zarządzanych przez projekty, które pod tym kątem analizują m. in.: Herroelen (2005), Katzel (1999), Kolisch (1999), Maroto i Tormos (1994), Mellentien i Trautmann (2001). W założeniach uwzględniono również możliwości modelowania dostępne w oprogramowaniu dla wspomagania zarządzania projektami¹.

¹Założenia w zakresie modelu danych przedsięwzięcia spełnia większość programów wspomagających zarządzanie projektami, chociaż w różnym stopniu m. in.: Microsoft Project [<http://office.microsoft.com/>], Primavera [<http://www.primavera.com/>], Merlin [<http://www.merlin2.net/>], Project Insight [<http://www.projectinsight.net/>], Open Workbench [<http://www.openworkbench.org/>]. Część oprogramowania umożliwia elastyczne modelowanie kosztów czynności, czy różnego rodzaju zasobów jak np. Microsoft Project, czy Primavera. Żaden z analizowanych programów nie pozwala na wariantowe modelowanie sposobu wykonania czynności. Można zauważyć istnienie rozbieżności pomiędzy osiągnięciami w badaniach naukowych nad optymalizacją harmonogramów i praktycznym ich zastosowaniem, które przedstawia Herroelen (2005).

4.1.2 Opis strukturalny modelu

Problem harmonogramowania realizacji projektów można zapisać jako:

$$\mathcal{PSP} = (\Pi, \Omega, \Xi, \Psi) \quad (4.1)$$

gdzie:

- Π – oznacza zbiór projektów,
- Ω – oznacza zbiór czynności do wykonania w ramach projektów,
- Ξ – oznacza zbiór relacji pomiędzy czynnościami (strukturę projektów),
- Ψ – oznacza zbiór zasobów różnych typów, wykorzystywanych dla realizacji czynności.

Dodatkowo poza modelem danych dla rozwiązania problemu $\mathcal{PSP}$ konieczne jest wskazanie kryterium i kierunku optymalizacji. Poniżej opisano kolejne elementy składowe problemu $\mathcal{PSP}$ oraz sformalizowano kryteria oceny dla tak sformułowanego modelu.

Projekty

Projekty oznaczone są kolejnymi liczbami całkowitymi począwszy od 1. Każdy z projektów składa się z określonej liczby $\tilde{\Omega}_i^\pi$ powiązanych ze sobą czynności, których identyfikatory zawarte są w zbiorze Ω_i^π . Wszystkie projekty korzystają ze wspólnej puli zasobów Ψ . Struktura każdego z projektów stanowi odrębną całość, nie są dozwolone relacje pomiędzy czynnościami z różnych projektów. Z realizacją projektu mogą być związane koszty stałe ponoszone w momencie uruchomienia ($\mathcal{E}fS_i^\pi$), w każdym okresie realizacji ($\mathcal{E}fP_i^\pi$), w chwili zakończenia projektu ($\mathcal{E}fF_i^\pi$). Każdy z projektów może mieć narzucony najwcześniejszy możliwy termin rozpoczęcia $S_{\pi i}^{\min}$ oraz termin zakończenia D_i^π , przekroczenie którego spowoduje zmniejszenie przychodów z tytułu zakończenia realizacji. Stawka kary za opóźnienie o jeden okres wynosi $\mathcal{E}L_i^\pi$. Przykładem stałych kosztów $\mathcal{E}fP_i^\pi$ związanych z realizacją projektu budowlanego, może być np. koszt ochrony terenu budowy, koszt obsługi administracyjnej, kosztem $\mathcal{E}fS_i^\pi$ może być np. koszt rejestracji podmiotu prawnego powołanego do realizacji projektu lub zrealizowanie procedury administracyjnej związanej z rejestracją projektu w organizacji wielo-projektowej.

Relacje

Zależności kolejnościowe pomiędzy czynnościami opisane są poprzez relacje Ξ . Z uwagi na możliwość przekształcenia każdego z czterech typów relacji w jeden wybrany (patrz zał. A) w dalszym opisie przyjęto, że wszystkie relacje w modelu są znormalizowane do typu $\mathbb{Z}\mathbb{R}$. Ponadto dowolna para czynności może połączona co najwyżej jedną relacją. Jeżeli istnieje relacja od czynności i do czynności j to element $\mathbb{Z}\mathbb{R}_{i \rightarrow j}^{\min}$ przyjmuje wartość 1 w przeciwnym wypadku wartość 0. Każda z relacji określona jest poprzez względne ograniczenia czasowe:

- minimalny czas jaki musi upłynąć od zakończenia czynności poprzedzającej i , aby można było rozpocząć czynność następującą j wynoszący $\mathbb{Z}\mathbb{R}_{i \rightarrow j}^{\min}$,
- maksymalny czas w trakcie którego od zakończenia czynności poprzedzającej i musi być rozpoczęta czynność następująca j wynoszący $\mathbb{Z}\mathbb{R}_{i \rightarrow j}^{\max}$.

Zasoby

W modelu wykorzystywane są trzy rodzaje zasobów: odnawialne, nieodnawialne oraz podwójnie ograniczone (modelowane jako jeden zasób odnawialny i jeden nieodnawialny zgodnie z opisem, który przedstawił Talbot (1982)). Każdy z zasobów ograniczony jest poprzez dostępną liczbę jednostek przy czym dla n -tego zasobu nieodnawialnego jest ona określona na początek okresu planowania i wynosi C_n'' , natomiast dla r -tego zasobu odnawialnego jest ona określona dla każdego okresu w ramach horyzontu planowania i w okresie t wynosi $\rho[r, t, C]$. Koszty związane z wykorzystaniem zasobów podzielono na:

- stałe – niezależne od liczby wykorzystywanych jednostek zasobu,
- zmienne – uzależnione od liczby jednostek zasobu oraz w przypadku zasobów odnawialnych czasu jego zaangażowania.

Jednocześnie koszty mogą być zróżnicowane w zależności od chwili ich wystąpienia: ponoszone wraz z rozpoczęciem czynności, ponoszone w każdym okresie wykorzystywania zasobu oraz ponoszone w chwili zakończenia realizacji czynności. Ogółem zatem dla i -tego zasobu można wyróżnić sześć stawek kosztów:

- $\mathcal{E}f\mathcal{S}_i^\psi$ – koszt stały ponoszony każdorazowo w chwili rozpoczęcia czynności wymagającej i -tego zasobu,
- $\mathcal{E}f\mathcal{P}_i^\psi$ – koszt stały ponoszony w każdym okresie realizacji czynności wymagającej i -tego zasobu,
- $\mathcal{E}f\mathcal{F}_i^\psi$ – koszt stały ponoszony każdorazowo w chwili zakończenia czynności wymagającej i -tego zasobu,
- $\mathcal{E}v\mathcal{S}_i^\psi$ – koszt zmienny ponoszony wraz z rozpoczęciem wykorzystywania jednej jednostki i -tego zasobu (w przypadku zasobów odnawialnych dodatkowo przez jeden okres czasu),
- $\mathcal{E}v\mathcal{P}_i^\psi$ – koszt zmienny ponoszony w każdym okresie wykorzystywania określony dla jednej jednostki i -tego zasobu (dotyczy tylko zasobów odnawialnych),
- $\mathcal{E}v\mathcal{F}_i^\psi$ – koszt zmienny ponoszony w chwili zakończenia wykorzystywania określony dla jednej jednostki i -tego zasobu (w przypadku zasobów odnawialnych dodatkowo przez jeden okres czasu).

W przypadku zasobów nieodnawialnych zróżnicowanie kosztów ze względu na termin powstania pozwala na precyzyjne określenie różnych sposobów płatności poza prostymi całość w chwili rozpoczęcia, czy zakończenia np. 20% kosztów ponoszonych jest w chwili rozpoczęcia czynności, a pozostałe 80% równomiernie w trakcie realizacji czynności². W związku z tym, że wielkość kosztów wykorzystania zasobów nieodnawialnych w odróżnieniu od odnawialnych jest niezależna od czasu trwania czynności stawki kosztów okresowych ($\mathcal{E}v\mathcal{P}_i^\psi$ i $\mathcal{E}f\mathcal{P}_i^\psi$) mają różne znaczenie w zależności od rodzaju zasobu. Dla zasobu nieodnawialnego stawka kosztu okresowego określona jest dla jednej jednostki zasobu i odpowiednio równomiernie rozkładany na wszystkie okresy realizacji czynności, w przypadku zasobu odnawialnego stawka ta traktowana jest jako kwota ponoszona dla jednej jednostki zasobu przez jeden okres czasu. W przypadku zaangażowania 2 jednostek zasobu nieodnawialnego (zmienny koszt okresowy = 3) w czynność o czasie trwania równym 5, koszt całkowity wyniesie $2 \times 3 = 6$ i zostanie rozłożony równomiernie w wielkości $\frac{6}{5}$ w każdym okresie realizacji czynności. W przypadku zasobu odnawialnego koszt całkowity wyniosłby $2 \times 3 \times 5 = 30$, co odpowiada wielkości $2 \times 3 = 6$ w każdym okresie.

Czynności

Czynności oznaczone są liczbami całkowitymi zaczynając od 1. Oznaczenia czynności są uporządkowane tak, aby wszystkie poprzedniki czynności i ($\omega_i^\ominus$) miały oznaczenie o wartości mniejszej od i natomiast wszystkie następniki ($\omega_i^\oplus$) miały oznaczenie o wartości większej od i :

$$\forall i \leq j \quad i \notin \omega_j^\oplus \quad (4.2)$$


$$\forall i \geq j \quad i \notin \omega_j^\ominus \quad (4.3)$$

Dla i -tej czynności określony jest zbiór bezpośrednich poprzedników ω_i^- oraz zbiór bezpośrednich następników ω_i^+ zgodnie z definicją relacji (Ξ):

$$\omega_i^- = \{j \mid \mathbb{Z}\mathbb{R}_{j \rightarrow i}^{\text{imi}} = 1\} \quad (4.4)$$

$$\omega_i^+ = \{j \mid \mathbb{Z}\mathbb{R}_{i \rightarrow j}^{\text{imi}} = 1\} \quad (4.5)$$

²Możliwe jest opisanie bardziej złożonych modeli kosztów w ramach przedstawionego formalizmu poprzez podzielnice czynności na dwie lub więcej i uwzględnienie np. ewentualnych opóźnień w relacjach (ograniczeniach względnych lub bezwzględnych) pomiędzy czynnościami. W efekcie uzyskamy czynność dodatkową np. realizacja płatności.



Rys. 4.1: Składniki kosztów w modelu harmonogramowania realizacji projektów

Zbiór wszystkich poprzedników i -tej czynności można określić jako:

$$\omega_i^{\ominus} = \omega_i^{-} \cup \sum_{j \in \omega_i^{-}} \omega_j^{\ominus} \quad (4.6)$$

oraz zbiór wszystkich następników i -tej czynności jako:

$$\omega_i^{\oplus} = \omega_i^{+} \cup \sum_{j \in \omega_i^{+}} \omega_j^{\oplus} \quad (4.7)$$

Wykonanie czynności może powodować uzyskanie płatności ze strony klienta w wielkości $\mathcal{I}_i^{\omega}$ w okresie w którym czynność została zakończona. Możliwe jest określenie najwcześniejszego ($\mathcal{S}_i^{\min}$) i najpóźniejszego ($\mathcal{S}_i^{\max}$) dozwolonego terminu realizacji i -tej czynności.

Zgodnie z założeniami do modelu przedstawionymi w p. 4.1.1 każda czynność może być zrealizowana na określonej skończonej liczbie sposobów. Realizacja czynności w określony sposób może powodować różne zaangażowanie zasobów, czas trwania i koszty – są to zmienne decyzyjne leżące po stronie wykonawcy projektu. Wielkość przychodów (płatności) i terminy ich zrealizowania są nie zależne od sposobu wykonania czynności.

Czynność i może być zrealizowana na $\tilde{\mathcal{M}}_i^{\omega}$ różnych sposobów. Sposoby wykonania są oznaczone kolejnymi liczbami całkowitymi zaczynając od 1. Z m -tym sposobem wykonania i -tej czynności związany jest czas realizacji czynności $\omega[i, m, \mathcal{T}]$. Realizacja czynności wymaga zaangażowania $\omega[i, m, \nu_r]$ jednostek r -tego zasobu nieodnawialnego wraz z rozpoczęciem jej realizacji oraz $\omega[i, m, \rho_s]$ jednostek s -tego zasobu odnawialnego w każdym okresie realizacji. Realizacja czynności i w sposób m może wymagać poniesienia kosztów stałych niezależnych od zasobów w chwili rozpoczęcia realizacji czynności ($\omega[i, m, \text{EfS}]$), w chwili zakończenia ($\omega[i, m, \text{EfF}]$) lub równomiernie w każdym okresie realizacji ($\omega[i, m, \text{EfP}]$).

4.1.3 Sformułowanie ograniczeń

Rozwiązanie sformułowanego powyżej problemu stanowi wykonalny harmonogram realizacji wszystkich projektów – uwzględniający wszelkie narzucone ograniczenia. Dla spełnienia warunku wykonalności harmonogramu konieczne jest:

- zachowanie założonej kolejności wykonywania czynności wraz ze względnymi ograniczeniami czasowymi,
- zachowanie bezwzględnych ograniczeń czasowych dla czynności,
- zachowanie ograniczenia dostępnej liczby jednostek zasobów nieodnawialnych,
- zachowanie ograniczenia dostępnej liczby jednostek zasobów odnawialnych w każdym okresie.

Ograniczenia kolejnościowe

Zachowanie założonej kolejności wykonywania czynności można ogólnie sformułować jako:

$$S_k^\omega \leq F_i^\omega \quad \{i\} \in \omega_k^\ominus \quad (4.8)$$

Dodatkowo terminy realizacji czynności nie mogą naruszać względnych ograniczeń czasowych, więc ograniczenie z równania 4.8 przyjmuje postać:

$$S_i^\omega \geq F_k^\omega + \mathbb{Z}\mathbb{R}_{i \rightarrow k}^{\min} \quad \{i\} \in \omega_k^- \quad (4.9)$$

$$S_i^\omega \leq F_k^\omega + \mathbb{Z}\mathbb{R}_{i \rightarrow k}^{\max} \quad \{i\} \in \omega_k^- \quad (4.10)$$

Czynność i nie może się rozpocząć dopóki od zakończenia k -tej czynności nie upłynie $\mathbb{Z}\mathbb{R}_{i \rightarrow k}^{\min}$ jednostek czasu oraz musi się rozpocząć nie później niż $\mathbb{Z}\mathbb{R}_{i \rightarrow k}^{\max}$ okresów od zakończenia i -tej czynności.

Bezwzględne ograniczenia czasowe

Bezwzględne ograniczenia czasowe można sformułować jako:

$$S_i^\omega \geq S_i^{\min} \quad (4.11)$$

$$S_i^\omega \leq S_i^{\max} \quad (4.12)$$

Termin rozpoczęcia i -tej czynności musi się zawierać pomiędzy $S_i^{\min}$ oraz $S_i^{\max}$. W szczególnym przypadku, gdy nie ma konieczności narzucania bezwzględnych ograniczeń czasowych $S_i^{\min} = 0$ lub $S_i^{\max} = \infty$.

Ograniczenia zasobowe

Wykorzystywana liczba jednostek odnawialnego zasobu i w okresie t określona jest jako:

$$\rho[i, t, \mathcal{U}] = \sum_{k=1}^{\tilde{\Omega}} \left\{ \omega[k, \mu_k, \rho_i] \mid S_k^\omega \leq t \leq F_k^\omega \right\} \quad (4.13)$$

dla zasobów nieodnawialnych natomiast:

$$\nu[i, t, \mathcal{U}] = \sum_{k=1}^{\tilde{\Omega}} \left\{ \omega[k, \mu_k, \nu_i] \mid t \geq S_k^\omega \right\} \quad (4.14)$$

Ograniczenie zaangażowania zasobów odnawialnych można sformułować jako:

$$\rho[i, t, \mathcal{U}] \leq \rho[i, t, C] \quad (4.15)$$

natomiast dla zasobów nieodnawialnych jako:

$$\nu[i, t_{max}, \mathcal{U}] \leq C_i^v \quad (4.16)$$

W żadnym z okresów realizacji zbioru projektów zapotrzebowanie sumaryczne na zasób odnawialny nie może przekroczyć jego dostępności w tymże okresie. natomiast dla zasobów nieodnawialnych sumaryczne zapotrzebowanie nie może przekroczyć dostępności tegoż zasobu (bez podziału czasowego).

Spełnienie ograniczenia sformułowanych w równaniach od 4.9 do 4.16 gwarantuje uzyskanie wykonalnego harmonogramu.

4.2 Sformułowanie kryteriów oceny

Poniżej przedstawiono matematyczny opis kryteriów oceny harmonogramu dla modelu danych problemu przedstawionego w p. 4.1.2.

4.2.1 Kryteria organizacyjne

Najczęściej stosowane w badaniach efektywności procedur harmonogramowania są kryteria oparte na charakterystyce czasowej harmonogramu. Prowadzone badania dowodzą, że poprawa rozwiązań ze względu na kryteria czasowe nie musi oznaczać poprawy ze względu na kryteria ekonomiczne (m.in. Russell (1970), Russell (1986)). Rozwiązania optymalne ze względu na kryteria ekonomiczne mogą być różne od rozwiązań optymalnych ze względu na kryteria czasowe³. Kryteria czasowe oparte są bezpośrednio na terminach realizacji prac. Termin rozpoczęcia projektu równy jest terminowi rozpoczęcia pierwszej z prac w ramach tegoż projektu:

$$\mathcal{S}_i^\pi = \min_{j \in \Omega_i^\pi} \{\mathcal{S}_j^\omega\} \quad (4.17)$$

Podobnie termin zakończenia projektu jest tożsamy z terminem zakończenia ostatniej z prac w ramach projektu:

$$\mathcal{F}_i^\pi = \max_{j \in \Omega_i^\pi} \{\mathcal{F}_j^\omega\} \quad (4.18)$$

Opóźnienie wykonania projektu wynosi:

$$\mathcal{L}_i^\pi = \max \{\mathcal{F}_i^\pi - \mathcal{D}_i^\pi, 0\} \quad (4.19)$$

Dla opracowanego modelu można sformułować następujące kryteria oceny:

1) **minimalizacja terminu zakończenia** realizacji zbioru projektów:

$$\max_{i=1, \dots, \Pi} \{\mathcal{F}_i^\pi\} \mapsto \min \quad (4.20)$$

2) **minimalizacja opóźnienia** realizacji zbioru projektów:

$$\sum_{i=1}^{\Pi} \mathcal{L}_i^\pi \mapsto \min \quad (4.21)$$

4.2.2 Kryteria ekonomiczne

Dla sformułowania kryteriów ekonomicznych konieczne jest powiązanie ze zbudowanym harmonogramem przepływów pieniężnych związanych z jednej strony kosztami realizacji projektów i czynności, wykorzystania zasobów, z drugiej zaś z przychodami z tytułu wykonania określonych prac, czy zakończenia projektu.

³Szczegółową analizę obliczeniową zależności kryteriów czasowych i ekonomicznych na przykładzie instancji sformułowanego modelu o $\Omega = 10$ przedstawiono w p. 6.4

Ujęcie statyczne kryterium opłacalności

Ujmując problem w sposób statyczny całkowity koszt realizacji i -tej czynności w m -ty sposób można określić jako sumę kosztów stałych czynności oraz kosztów zasobów wykorzystanych do realizacji tejże czynności. Koszt stały realizacji i -tej czynności wynosi:

$$\omega[i, m, \mathcal{E}f] = \omega[i, m, \mathcal{E}f\mathcal{S}] + \omega[i, m, \mathcal{E}f\mathcal{F}] + \omega[i, m, \mathcal{T}] * \omega[i, m, \mathcal{E}f\mathcal{P}] \quad (4.22)$$

Koszt wykorzystania zasobów odnawialnych w i -tej czynności można obliczyć jako:

$$\begin{aligned} \omega[i, m, \mathcal{E}_\rho] = & \sum_{r=1}^{\tilde{\Psi}_R} (\mathcal{E}v\mathcal{S}_r^\rho + \mathcal{E}v\mathcal{P}_r^\rho * \omega[i, m, \mathcal{T}] + \mathcal{E}v\mathcal{F}_r^\rho) * \omega[i, m, \rho_r] + \\ & + \sum_{r=1}^{\tilde{\Psi}_R} \{ \mathcal{E}f\mathcal{S}_r^\rho + \mathcal{E}f\mathcal{P}_r^\rho + \mathcal{E}f\mathcal{F}_r^\rho \mid \omega[i, m, \rho_r] > 0 \} \end{aligned} \quad (4.23)$$

Podobnie koszt wykorzystania zasobów nieodnawialnych:

$$\begin{aligned} \omega[i, m, \mathcal{E}_v] = & \sum_{n=1}^{\tilde{\Psi}_N} (\mathcal{E}v\mathcal{S}_n^\nu + \mathcal{E}v\mathcal{P}_n^\nu + \mathcal{E}v\mathcal{F}_n^\nu) * \omega[i, m, v_n] + \\ & + \sum_{n=1}^{\tilde{\Psi}_N} \{ \mathcal{E}f\mathcal{S}_n^\nu + \mathcal{E}f\mathcal{P}_n^\nu + \mathcal{E}f\mathcal{F}_n^\nu \mid \omega[i, m, v_n] > 0 \} \end{aligned} \quad (4.24)$$

Całkowity koszt realizacji i -tej czynności wynosi:

$$\omega[i, m, \mathcal{E}] = \omega[i, m, \mathcal{E}f] + \omega[i, m, \mathcal{E}_\rho] + \omega[i, m, \mathcal{E}_v] \quad (4.25)$$

Koszt stały i -tego projektu stanowi sumę kosztów stałych ponoszonych przy rozpoczęciu, zakończeniu w każdym okresie realizacji projektu i wynosi:

$$\mathcal{E}f_i^\pi = \mathcal{E}f\mathcal{S}_i^\pi + \mathcal{E}f\mathcal{P}_i^\pi * (\mathcal{F}_i^\pi - \mathcal{S}_i^\pi + 1) + \mathcal{E}f\mathcal{F}_i^\pi \quad (4.26)$$

Koszt całkowity związany z realizacją i -tego projektu wynosi:

$$\mathcal{E}_i^\pi = \mathcal{E}f_i^\pi + \sum_{j=1}^{\tilde{\Omega}} \{ \omega[j, m, \mathcal{E}] \mid j \in \Omega_i^\pi \} \quad (4.27)$$

Przychody związane ze zrealizowaniem i -tego projektu wynoszą:

$$\mathcal{I}_i^\pi = \sum_{j=1}^{\tilde{\Omega}} \{ \mathcal{I}_j^\omega \mid j \in \Omega_i^\pi \} - \mathcal{L}_i^\pi * \mathcal{E}\mathcal{L}_i^\pi \quad (4.28)$$

Zatem kryterium **maksymalizacji zyskowności** realizacji zbioru projektów Π ma postać:

$$\sum_{i=1}^{\tilde{\Pi}} (\mathcal{I}_i^\pi - \mathcal{E}_i^\pi) \mapsto \max \quad (4.29)$$

Ujęte w powyższy sposób kryterium oceny ma charakter statyczny. Podstawową wadą takiego podejścia w ocenie harmonogramu realizacji zbioru projektów jest znikoma zależność pomiędzy kolejnością realizacji prac, a efektem ekonomicznym. Na uzyskany efekt ekonomiczny główny wpływ ma sposób wykonania czynności $(\mu_1, \dots, \mu_{\tilde{\Omega}})$. Zmiany w kosztach spowodowane kolejnością realizacji prac objawiają się jedynie w postaci zmian kosztów stałych projektu oraz zmniejszenia przychodów z projektu z powodu opóźnienia terminu realizacji. Bardziej precyzyjnej oceny ekonomicznej harmonogramu realizacji projektów można dokonać posługując się metodą dyskontowania przepływów pieniężnych. Pozwoli ona na zaktualizowanie wartości przyszłych wpływów i wydatków na chwilę bieżącą, dzięki czemu będą one porównywalne bez utraty istotnych informacji o momencie ich wystąpienia.

Dynamiczne podejście do oceny harmonogramu realizacji projektu polega na określeniu kosztów i przychodów wraz z terminem ich wystąpienia, a następnie zdyskontowaniu ich wartości na dowolny termin (zwykle początek harmonogramu – chwilę *bieżącą*). Przy podejściu dynamicznym zastosowano identyczny układ kosztów i przychodów uszczegóławiając go terminami wystąpienia. Koszt stały związany z realizacją i -tej czynności w m -ty sposób w okresie t wynosi:

$$\omega[i, m, t, \mathcal{E}f] = \begin{cases} 0 & \text{dla } t \notin \langle \mathcal{S}_i^\omega, \mathcal{F}_i^\omega \rangle \\ \omega[i, m, \mathcal{E}f\mathcal{S}] + \omega[i, m, \mathcal{E}f\mathcal{P}] & \text{dla } t = \mathcal{S}_i^\omega \\ \omega[i, m, \mathcal{E}f\mathcal{P}] & \text{dla } t \in (\mathcal{S}_i^\omega, \mathcal{F}_i^\omega) \\ \omega[i, m, \mathcal{E}f\mathcal{F}] + \omega[i, m, \mathcal{E}f\mathcal{P}] & \text{dla } t = \mathcal{F}_i^\omega \end{cases} \quad (4.30)$$

Koszt wykorzystania zasobów odnawialnych związany z realizacją i -tej czynności w m -ty sposób w okresie t wynosi:

$$\omega[i, m, t, \mathcal{E}_\rho] = \begin{cases} 0 & \text{dla } t \notin \langle \mathcal{S}_i^\omega, \mathcal{F}_i^\omega \rangle \\ \sum_{r=1}^{\tilde{\Psi}_R} \{ \mathcal{E}f\mathcal{S}_r^\rho + \mathcal{E}f\mathcal{P}_r^\rho \mid \omega[i, m, \rho_r] > 0 \} + \\ \quad + \sum_{r=1}^{\tilde{\Psi}_R} (\mathcal{E}v\mathcal{S}_r^\rho + \mathcal{E}v\mathcal{P}_r^\rho) * \omega[i, m, \rho_r] & \text{dla } t = \mathcal{S}_i^\omega \\ \sum_{r=1}^{\tilde{\Psi}_R} \{ \mathcal{E}f\mathcal{P}_r^\rho \mid \omega[i, m, \rho_r] > 0 \} + \\ \quad + \sum_{r=1}^{\tilde{\Psi}_R} \mathcal{E}v\mathcal{P}_r^\rho * \omega[i, m, \rho_r] & \text{dla } t \in (\mathcal{S}_i^\omega, \mathcal{F}_i^\omega) \\ \sum_{r=1}^{\tilde{\Psi}_R} \{ \mathcal{E}f\mathcal{F}_r^\rho + \mathcal{E}f\mathcal{P}_r^\rho \mid \omega[i, m, \rho_r] > 0 \} + \\ \quad + \sum_{r=1}^{\tilde{\Psi}_R} (\mathcal{E}v\mathcal{F}_r^\rho + \mathcal{E}v\mathcal{P}_r^\rho) * \omega[i, m, \rho_r] & \text{dla } t = \mathcal{F}_i^\omega \end{cases} \quad (4.31)$$

Podobnie koszt wykorzystania zasobów nieodnawialnych:

$$\omega[i, m, t, \mathcal{E}_v] = \begin{cases} 0 & \text{dla } t \notin \langle \mathcal{S}_i^\omega, \mathcal{F}_i^\omega \rangle \\ \sum_{n=1}^{\tilde{\Psi}_N} \{ \mathcal{E}f\mathcal{S}_n^\nu + \mathcal{E}f\mathcal{P}_n^\nu \mid \omega[i, m, \nu_n] > 0 \} + \\ \quad + \sum_{n=1}^{\tilde{\Psi}_N} \left(\mathcal{E}v\mathcal{S}_n^\nu + \frac{\mathcal{E}v\mathcal{P}_n^\nu}{\omega[i, m, \mathcal{T}]} \right) * \omega[i, m, \nu_n] & \text{dla } t = \mathcal{S}_i^\omega \\ \sum_{n=1}^{\tilde{\Psi}_N} \{ \mathcal{E}f\mathcal{P}_n^\nu \mid \omega[i, m, \nu_n] > 0 \} + \\ \quad + \sum_{n=1}^{\tilde{\Psi}_N} \frac{\mathcal{E}v\mathcal{P}_n^\nu}{\omega[i, m, \mathcal{T}]} * \omega[i, m, \nu_n] & \text{dla } t \in (\mathcal{S}_i^\omega, \mathcal{F}_i^\omega) \\ \sum_{n=1}^{\tilde{\Psi}_N} \{ \mathcal{E}f\mathcal{F}_n^\nu + \mathcal{E}f\mathcal{P}_n^\nu \mid \omega[i, m, \nu_n] > 0 \} + \\ \quad + \sum_{n=1}^{\tilde{\Psi}_N} \left(\mathcal{E}v\mathcal{F}_n^\nu + \frac{\mathcal{E}v\mathcal{P}_n^\nu}{\omega[i, m, \mathcal{T}]} \right) * \omega[i, m, \nu_n] & \text{dla } t = \mathcal{F}_i^\omega \end{cases} \quad (4.32)$$

Koszt stały realizacji i -tego projektu w okresie t wynosi:

$$\pi[i, t, \mathcal{E}f] = \begin{cases} 0 & \text{dla } t \notin \langle \mathcal{S}_i^\pi, \mathcal{F}_i^\pi \rangle \\ \mathcal{E}f\mathcal{S}_i^\pi + \mathcal{E}f\mathcal{P}_i^\pi & \text{dla } t = \mathcal{S}_i^\pi \\ \mathcal{E}f\mathcal{P}_i^\pi & \text{dla } t \in (\mathcal{S}_i^\pi, \mathcal{F}_i^\pi) \\ \mathcal{E}f\mathcal{F}_i^\pi + \mathcal{E}f\mathcal{P}_i^\pi & \text{dla } t = \mathcal{F}_i^\pi \end{cases} \quad (4.33)$$

Wydatki związane z realizacją określonego harmonogramu w okresie t można sformułować jako:

$$\mathcal{E}_t = \sum_{i=1}^{\bar{\Omega}} \left(\omega[i, m, t, \mathcal{E}f] + \omega[i, m, t, \mathcal{E}_\rho] + \omega[i, m, t, \mathcal{E}_v] \right) + \pi[i, t, \mathcal{E}f] \quad (4.34)$$

Wpływy związane są bezpośrednio z wykonaniem określonych czynności i są niezależne od sposobu w jaki czynność została wykonana. Wpływy z tytułu realizacji i -tego projektu w chwili t wynoszą:

$$\pi[i, t, \mathcal{I}] = \sum_{j \in \Omega_i^\pi} \left\{ \mathcal{I}_j^\omega \mid t = \mathcal{F}_j^\omega \right\} - \left\{ \mathcal{L}_i^\pi * \mathcal{E}\mathcal{L}_i^\pi \mid t = \mathcal{F}_i^\pi \right\} \quad (4.35)$$

Całkowite wpływy związane z realizacją harmonogramu w okresie t można sformułować jako:

$$\mathcal{I}_t = \sum_{i=1}^{\bar{\Pi}} \pi[i, t, \mathcal{I}] \quad (4.36)$$

Ogółem saldo pieniężne netto w okresie t określono jako:

$$\text{NCF}_t = \mathcal{I}_t - \mathcal{E}_t \quad (4.37)$$

Zdyskontowane (bieżące) saldo pieniężne okresu t przy stopie dyskontowej równej d wynosi:

$$\text{NPV}_t^d = \frac{\text{NCF}_t}{(1 + d)^t} \quad (4.38)$$

Skumulowane zdyskontowane saldo pieniężne wynosi:

$$\text{NPV}_{t_{\max}}^d = \sum_{t=1}^{t_{\max}} \text{NPV}_t^d \quad (4.39)$$

Jako najistotniejsze dla oceny efektywności ekonomicznej stosowania badanej procedury w warunkach wybranej klasy problemów uznano kryterium maksymalizacji skumulowanej zdyskontowanej wartości przepływów pieniężnych przy założonej stopie dyskontowej d zapisane jako:

$$\text{NPV}_{t_{\max}}^d \mapsto \max \quad (4.40)$$

Jest to kryterium mające charakter syntetyczny, uwzględniające ocenę wszystkich podjętych na etapie harmonogramowania decyzji wyrażoną w jednostce pieniężnej. Stosowanie w przypadku powyżej sformułowanego problemu harmonogramowania kryteriów nie uwzględniających zmiany wartości pieniądza w czasie jest stanowczo niewystarczające. W przypadku zastosowania NCF zmiany wartości kryterium byłyby odzwierciedleniem zmian efektu wynikającego jedynie z wpływu doboru sposobu realizacji czynności μ_i , natomiast zmiany terminów realizacji czynności (czy zmiany kolejności wykonywania czynności, wyrażone poprzez Q_i^ω) nie miałyby wpływu na wartość tak określonego kryterium.

4.3 Normalizacja problemu

Dla zredukowania rozmiaru problemu i poprawy efektywności pracy algorytmów wprowadzono normalizację problemu w sposób oparty na rozwiązaniach, które w dokładnym algorytmie podziału i ograniczeń zastosowali Sprecher i Drexler (1996a). Normalizacja problemu pozwala na ograniczenie przestrzeni poszukiwań bez wpływu na możliwość osiągnięcia rozwiązania optymalnego. Normalizacja polega na usunięciu z modelu:

- niewykonalnych sposobów wykonania,
- nieefektywnych sposobów wykonania,
- nadmiarowych zasobów nieodnawialnych.

Sposób m -ty wykonania j -tej czynności można uznać za niewykonalny, jeżeli realizacja powoduje przekroczenie dostępnej liczby jednostek dowolnego n -tego zasobu nieodnawialnego (przy założeniu sposobów wykonania pozostałych czynności o minimalnym zużyciu tegoż zasobu):

$$\omega[j, m, v_n] + \sum_{\substack{i=1 \\ i \neq j}}^{\tilde{\Omega}} \left\{ \min_{p=1, \dots, \mathcal{M}_i^{\omega}} \{ \omega[i, p, v_n] \} \right\} > C_n^v \quad (4.41)$$

Sposób m -ty realizacji i -tej czynności jest nieefektywny, jeżeli jest możliwa realizacja i -tej czynności w inny q -ty sposób, który pozwala na uzyskanie jednocześnie większych przepływów pieniężnych:

$$\omega[i, m, \text{NPV}^d] \leq \omega[i, q, \text{NPV}^d] \quad (4.42)$$

w takim samym lub krótszym czasie:

$$\omega[i, m, \mathcal{T}] \geq \omega[i, q, \mathcal{T}] \quad (4.43)$$

przy takim samym lub mniejszym zapotrzebowaniu na zasoby odnawialne:

$$\forall_{r=1, \dots, \tilde{\Psi}_R} \quad \omega[i, m, \rho_r] \geq \omega[i, q, \rho_r] \quad (4.44)$$

oraz przy takim samym lub mniejszym zapotrzebowaniu na zasoby nieodnawialne:

$$\forall_{r=1, \dots, \tilde{\Psi}_N} \quad \omega[i, m, v_r] \geq \omega[i, q, v_r] \quad (4.45)$$

Jeżeli ograniczenie liczby dostępnych jednostek jest spełnione dla każdego punktu w przestrzeni sposobów wykonania czynności to n -ty zasób nieodnawialny można uznać za nadmiarowy:

$$\sum_{i=1}^{\tilde{\Omega}} \left\{ \max_{m=1, \dots, \mathcal{M}_i^{\omega}} \{ \omega[i, m, v_n] \} \right\} \leq C_n^v \quad (4.46)$$

Usunięcie niewykonalnych sposobów wykonania czynności i nadmiarowych zasobów nieodnawialnych nie ma wpływu na zbiór rozwiązań dopuszczalnych sformułowanego modelu. Natomiast usunięcie nieefektywnych sposobów wykonania nie ma wpływu na możliwość osiągnięcia rozwiązania optymalnego. Po przeprowadzeniu normalizacji problemu uzyskujemy problem RCPS w formie, która charakteryzuje się mniejszą złożonością obliczeniową przy całkowitym zachowaniu wszelkich uwarunkowań.

4.4 Podsumowanie

Zbudowanie harmonogramu przedsięwzięcia wymaga uwzględnienia znacznej liczby różnego rodzaju informacji o strukturze projektu, wykorzystywanych zasobach, różnych możliwościach realizacji czynności, czy dostępnych środkach pieniężnych. Sformułowany model harmonogramowania projektów z uwzględnieniem czynników ekonomicznych pozwala na ocenę jakości harmonogramu na podstawie wartości zaktualizowanej netto i integrację z procedurami optymalizacji opartymi na nowoczesnych metaheurystykach. Uwzględnienie informacji o wpływach i wydatkach związanych z realizacją prac na etapie budowy harmonogramu (gdzie podejmowane są decyzje o alokacji zasobów i terminach realizacji czynności) powinno pozwolić na efekcie na uzyskanie zadowalających z finansowego punktu widzenia harmonogramów realizacji prac.

Procedury optymalizacji efektów ekonomicznych realizacji harmonogramu

Niniejszy rozdział zawiera charakterystykę wybranych metaheurystyk, które mogą być stosowane w optymalizacji efektów ekonomicznych realizacji harmonogramu realizacji projektów. Kolejno opisano elementy składowe konstrukcji procedur poczynając od sposobu reprezentacji (kodowania) problemu, poprzez techniki eksploracji i eksploatacji, aż po strategię poszukiwania właściwe dla poszczególnych metod.

Metaheurystyki można podzielić na dwie grupy (Blum i Roli, 2001, Vaessens i in., 1998):


- **m. operujące na jednym rozwiązaniu** – w ramach procedury tworzone jest początkowe rozwiązanie (w sposób losowy lub z wykorzystaniem prostych metod heurystycznych – w przypadku problemu harmonogramowania z wykorzystaniem np. reguł priorytetu), następnie w kolejnych iteracjach tworzone jest jedno rozwiązanie wybierane losowo z sąsiedztwa (otoczenia) rozwiązania z poprzedniej iteracji algorytmu w efekcie powstaje trajektoria przeszukanych punktów w przestrzeni poszukiwań. Do tej grupy można zaliczyć m.in.: algorytmy poszukiwania lokalnego, symulowane wyżarzanie, poszukiwanie z ruchami zabronionymi.
- **m. oparte na populacji osobników** – w ramach procedury tworzona jest grupa (populacja) rozwiązań, w kolejnych iteracjach powstają kolejne grupy rozwiązań oparte na rozwiązaniach z poprzedniej iteracji. Do tej grupy można zaliczyć m.in.: algorytmy genetyczne, algorytm uczenia populacji, algorytmy kulturowe, przeszukiwanie rozproszone, algorytm kolonii mrówek.

Metaheurystyki dla problemów harmonogramowania reprezentują podejście określane mianem czarnej skrzynki (ang. *black box optimization*). Oznacza to, że algorytm poszukujący operuje na przestrzeni parametrów, które poprzez procedurę ewaluacji przekształcane są w rozwiązanie i oceniane, ta z kolei wartość oceny jest przekazywana z powrotem do algorytmu poszukiwania i jest wykorzystywana dla ukierunkowania dalszego procesu szukania. Dla opisywanych w pracy rozwiązań zależności te przedstawiono na rys. 5.1.

5.1 Kodowanie problemu harmonogramowania projektów¹

Większość algorytmów metaheurystycznych nie operuje bezpośrednio na rozwiązaniu lecz na jego zakodowanej formie. Kluczową rolę w konstruowaniu algorytmu odgrywają dwa czynniki: (1) sposób zdefiniowania (zakodowania) przestrzeni poszukiwań, (2) sposób generowania otoczenia punktu w przestrzeni rozwiązań. Od jakości zdefiniowanego otoczenia zależy efektywność działania procedury. Z drugiej strony sposób generowania otoczenia ma kluczowy wpływ na efektywność czasową procedury, gdyż nierzadko jest powtarzany wielokrotnie w każdej iteracji algorytmu i gdy jest nadmiernie złożony może znacznie spowolnić działanie całej procedury. Kodowanie przestrzeni rozwiązań w przestrzeń parametrów może być realizowane na różne sposoby. Na rys. 5.2 przedstawiono zależności pomiędzy opisanymi przestrzeniami.

¹część materiału zawartego w niniejszym punkcie została opublikowana w pracy (Kostrubiec, 2001a)



Rys. 5.1: Zależność pomiędzy procedurą budowy i optymalizacji harmonogramu

Podstawowym zadaniem schematu kodowania jest odwzorowanie całej przestrzeni rozwiązań w przestrzeni parametrów. Możliwe są trzy rodzaje relacji:

- **jeden-do-jeden** – jednemu parametrowi odpowiada dokładnie jedno rozwiązanie, wielkość przestrzeni rozwiązań jest równa wielkości przeszukiwanej przez algorytm przestrzeni parametrów,
- **wiele-do-jeden** – z wielu parametrów można uzyskać to samo rozwiązanie, cała przestrzeń rozwiązań jest odwzorowana jednak w sposób, który powoduje, że przeszukiwana przez algorytm przestrzeń parametrów jest większa od przestrzeni rozwiązań – zarówno parametry p_1 jak i p_3 wyznaczają rozwiązanie r_1 ,
- **jeden-do-wielu** – z jednego parametru można wyprowadzić wiele rozwiązań, parametry nie identyfikują w sposób jednoznaczny rozwiązania – wynikowe parametry nie są wystarczające dla odczytania rozwiązania – aby z parametru p_1 uzyskać rozwiązanie trzeba dodatkowo podjąć decyzję, która pozwoli wybrać czy będzie to r_1 czy r_3 .


Najbardziej pożądanym typem jest relacja jeden-do-jeden – pozwala odwzorować całą przestrzeń poszukiwania w minimalnej liczbie kombinacji parametrów. Gorszym rozwiązaniem jest relacja wiele-do-jeden ze względu na zwiększenie przestrzeni poszukiwań. Najgorszą ze względu na niejednoznaczność parametrów jest relacja jeden-do-wielu. Z problemem kodowania wiąże się problem procedury dekodującej, często zawierającej mechanizm naprawy wadliwych (nadmiarowych) rozwiązań.

5.1.1 Reprezentacja problemu – kodowanie

Rozwiązaniem problemu harmonogramowania jest co najmniej ciąg terminów rozpoczęcia (bądź zakończenia) kolejnych zadań, jednak większość metod optymalizacyjnych nie operuje bezpośrednio na tymże rozwiązaniu zastępując je inną strukturą danych. Dodatkowo w przypadku modeli z wieloma sposobami wykonania należy podać na który sposób czynność ma być wykonana. W efekcie rozwiązanie problemu zdefiniowane jest poprzez ciąg par:

$$R=((S_1^\omega, \mu_1), \dots, (S_i^\omega, \mu_i), \dots, (S_\Omega^\omega, \mu_\Omega)) \quad (5.1)$$

Ponieważ wybór sposobu wykonania czynności jest zawsze modelowany w formie bezpośredniej w dalszej części dla uproszczenia zapisu przedstawiono sposób kodowania problemu z jednym sposobem wykonania czynności.



Rys. 5.2: Rodzaje relacji pomiędzy przestrzenią parametrów i rozwiązań

W przypadku **reprezentacji bezpośredniej** algorytm pracuje na ciągu terminów rozpoczęcia (bądź zakończenia) realizacji zadań, czyli na rozwiązaniu zadania:

$$P = (\mathcal{S}_1^\omega, \dots, \mathcal{S}_i^\omega, \dots, \mathcal{S}_{\bar{\Omega}}^\omega) \quad (5.2)$$

Jednak nawet w przypadku ogólnych problemów harmonogramowania zastosowanie tego rodzaju reprezentacji wiąże się z koniecznością stosowania złożonych procedur generowania osobnika z sąsiedztwa lub procedur naprawy (Yamada i Nakano, 1992). Jedynie Thomas i Salhi (1998) wykorzystują tego typu reprezentację w modelu **RCPS** z jednym sposobem wykonania czynności (w przypadku uzyskania rozwiązań niespełniających ograniczeń stosują karę).

Reprezentacja permutacyjna (ang. *permutation, activity-list*) stosowana była początkowo w metaheurystykach dla rozwiązywania problemu komiwojażera i problemu plecakowego. Davis (1985b) zastosował po raz pierwszy ten rodzaj reprezentacji w **GA** dla ogólnego problemu harmonogramowania. Od tego czasu jest to najpowszechniej stosowany sposób kodowania problemów harmonogramowania zarówno klasycznych (m.in. Bierwirth i Mattfeld (1999), Falkenauer i Bouffouix (1991), Ponnambalam, Aravindan i Rajesh (2000), Reeves i Yamada (1998), Syswerda (1991)), jak i projektowych (m.in. Boctor (1996b), Bouleimen i Lecocq (1998), Hartmann (1997), Józefowska, Mika, Różycki, Waligóra i Węglarz (2000, 2001), Pinson, Prins i Rullier (1994), Ulusoy, Sivrikaya-Şerifoğlu i Şahin (2001)). W przypadku problemów typu projektowego przyjmuje się zwykle dla redukcji wielkości przestrzeni poszukiwań założenie, że czynność występuje w ciągu po wszystkich poprzednikach i przed wszystkimi następnikami – brak tego założenia występuje w procedurze generowania sąsiada w badaniach, które prowadzą Gemmill i Tsai (1997), Tsai i Gemmill (1998). Ogólnie zestaw parametrów rozwiązania można zapisać jako uszeregowanie czynności w postaci:

$$P = (p_1, \dots, p_i, \dots, p_{\bar{\Omega}}) \quad | \quad p_i \in \Omega, \quad \bigwedge_{i \neq k} p_i \neq p_k \quad (5.3)$$

Reprezentację reguł priorytetu (ang. *priority rule based*) zaproponowali po raz pierwszy Dorndorf i Pesch (1995) dla warunków ogólnego problemu harmonogramowania. Procedury wykorzystujące tego rodzaju reprezentację w problemach projektowych przedstawiają Hartmann (1997), Özdamar (1999). Parametrem określającym rozwiązanie jest tu ciąg o długości równej liczbie operacji, w którym każdemu elementowi jest przypisana reguła priorytetu z uprzednio wyselekcjonowanego zbioru:

$$P = (p_1, \dots, p_i, \dots, p_{\bar{\Omega}}) \quad | \quad p_i \in \{\text{SPT, LPT, MTS, MSLK, ...}\} \quad (5.4)$$

Reprezentację wartości priorytetu oryginalnie nazywaną *random keys representation*, którą opracował Bean (1994) w problemach projektowych stosują m.in. Cho i Kim (1997), Hartmann (2001), Kohlmorgen,

Schmeck i Haase (1996), Lee i Kim (1996), Leon i Balakrishnan (1995), Zhang, Li i Tam (2006b). Parametrem definiującym rozwiązanie jest tu ciąg liczb z zakresu $(0, 1)$ odpowiadających wartościom priorytetu czynności:

$$P = (p_1, \dots, p_i, \dots, p_{\bar{\Omega}}) \quad | \quad p_i \in (0, 1) \quad (5.5)$$

Sampson i Weiss (1993), Wall (1996) stosują kodowanie rozwiązania w postaci **wektora opóźnienia** (ang. *shift vector representation*). Rozwiązanie jest reprezentowane przez ciąg liczb nieujemnych, z których każda określa opóźnienie czynności w harmonogramie względem najwcześniejszego możliwego terminu realizacji (zgodnie z ograniczeniami kolejnościowymi i czasowymi):

$$P = (p_1, \dots, p_i, \dots, p_{\bar{\Omega}}) \quad | \quad p_i \geq 0 \quad (5.6)$$

Z punktu widzenia kodowania wyróżniają się dwa schematy: bezpośredni i wektora opóźnienia, ponieważ nie wymagają stosowania procedur przekształcania parametrów w harmonogram (jednak towarzyszy im procedura rozwiązująca konflikty zasobowe, bądź kolejnościowe po operacjach rekombinacji, czyli przekształcająca powstały harmonogram niewykonalny w wykonalny). Pozostałe schematy kodowania w istocie określają na różne sposoby względną ważność czynności na podstawie której ustalana jest w procedurze dekodującej kolejność ich umieszczania w harmonogramie.

W świetle opublikowanych wyników badań (Alcaraz i Maroto, 2001, Bouleimen i Lecocq, 2003, Hartmann, 2001) najlepsze efekty uzyskują procedury oparte na reprezentacji permutacyjnej niezależnie od stosowanych metaheurystyk. Z tego względu w niniejszej pracy zdecydowano się na implementację procedur optymalizacyjnych opartych na tym właśnie schemacie kodowania.

5.2 Procedury dekodowania dla reprezentacji permutacyjnej

Z wybranym schematem kodowania związana jest procedura kodowania/dekodowania, czyli przekształcania parametrów w rozwiązanie (np. uszeregowania w harmonogram) i odwrotnie. W problemach harmonogramowania projektów stosowane są w tym celu procedury budowy harmonogramu (ang. *SGS – Schedule Generation Scheme*) dwójakiego rodzaju: szeregowe i równoległe. Poza funkcją kodującą/dekodującą mogą one stanowić narzędzie pozwalające naprawić lub uzupełnić zestaw parametrów uszkodzonych wskutek operacji rekombinacji. Ogólnie procedurę kodującą można zapisać jako odwzorowanie przestrzeni parametrów w przestrzeń rozwiązań:

$$SGS : R_i = sgS(P_i) \quad (5.7)$$

Zadaniem procedury budowy harmonogramu jest przekształcenie parametrów rozwiązania w harmonogram, czyli przekształcenie np. ciągu sposobów wykonania oraz uszeregowania czynności w harmonogram realizacji.

W opisywanym modelu założono budowanie harmonogramu dla wstępnie zdefiniowanego w wyniku działania algorytmu optymalizacji sposobów wykonania czynności $(\mu_1, \dots, \mu_{\bar{\Omega}})$. Przed rozpoczęciem budowy harmonogramu sprawdzana jest możliwość utworzenia wykonalnego harmonogramu w oparciu o tenże ciąg zgodnie z równaniami 4.14 i 4.16. Etap sprawdzenia jest wspólny dla wszystkich poniżej opisanych procedur.

Procedurę szeregową zaproponował Kelly (1963). Zastosowanie tejże procedury w sposób jednorzeczowy badaniach opisują m.in. Boctor (1990), Cooper (1976), Heilmann (2001), Kolisch (1996b). Jako procedurę wielokrotną stosowali ją m.in. Boctor (1990), Cooper (1976), Kolisch (1996b). Przedstawiona na alg. 5.1 procedura nie uwzględnia sprawdzenia wykonalności ciągu $(\mu_1, \dots, \mu_{\bar{\Omega}})$ sposobów realizacji czynności ze względu na ograniczenie dostępności zasobów nieodnawialnych.

Podobnie jak procedurę szeregową, **procedurę równoległą** opisał po raz pierwszy Kelly (1963). Jako procedura jednokrotna wykorzystywana była ona w badaniach, które opisali m.in. Boctor (1990, 1993, 1996a,b), Davis i Patterson (1975), Elsayed (1982), Kolisch (1996b), Thesen (1976), Ulusoy i Özdamar (1994), również jako wielokrotną: Boctor (1990), Wiest (1967). Przedstawiona na alg. 5.2 procedura nie uwzględnia etapu sprawdzenia wykonalności danego ciągu $(\mu_1, \dots, \mu_{\bar{\Omega}})$ realizacji czynności ze względu na ograniczenie dostępności zasobów nieodnawialnych.

```

begin
   $n \leftarrow 1, S_0 \leftarrow \emptyset$ 
   $\rho[i, t, \mathcal{A}] \leftarrow \rho[i, t, C]$ 
  while  $|S_n| < \tilde{\Omega}$  do
     $D_n \leftarrow \{i \mid i \notin S_n, \omega_i^- \subseteq S_n\}$ 
     $t_{\max} \leftarrow \max\{\mathcal{F}_k^\omega \mid \{k\} \in S_n\}$ 
    oblicz  $\rho[i, t, \mathcal{A}]$  dla  $t = 1, \dots, t_{\max}, i = 1, \dots, \tilde{\Psi}_R$ 
     $p \leftarrow \max\{Q_i^\omega \mid i \in D_n\}$ 
     $j \leftarrow \min_{i \in D_n}\{i \mid Q_i^\omega = p\}$ 
     $s_{\min} \leftarrow \max\{\mathcal{F}_i^\omega \mid i \in \omega_j^-\}$ 
     $S_j^\omega \leftarrow \min\{t^\star \mid \omega[j, \mu_j, \rho_i] \leq \rho[i, t, \mathcal{A}]$ 
       $i = 1, \dots, \tilde{\Psi}_R, t = s_{\min} + t^\star, \dots, s_{\min} + t^\star + \omega[j, \mu_j, \mathcal{T}]\}$ 
     $\mathcal{F}_j^\omega \leftarrow S_j^\omega + \omega[j, \mu_j, \mathcal{T}]$ 
     $S_{n+1} \leftarrow S_n \cup \{j\}$ 
     $n \leftarrow n + 1$ 
  end while
end

```

Alg. 5.1: Szeregową procedurą budowy harmonogramu

```

begin
   $n \leftarrow 1, t_1 \leftarrow 1, A_1, S_1 \leftarrow \emptyset$ 
   $P_1 \leftarrow \{i \mid \omega_i^- = \emptyset\}$ 
   $D_1 \leftarrow \{i \mid i \in P_1, \rho[k, t^\star, \mathcal{A}] \geq \omega[i, \mu_i, \rho_k]$ 
     $t^\star = t_1, \dots, t_1 + \omega[i, \mu_i, \mathcal{T}], k = 1, \dots, \tilde{\Psi}_R\}$ 
  while  $|S_n \cup A_n| < \tilde{\Omega}$  do
    repeat
       $p \leftarrow \max\{Q_i^\omega \mid i \in D_n\}$ 
       $j \leftarrow \min_{i \in D_n}\{i \mid Q_i^\omega = p\}$ 
       $S_j^\omega \leftarrow t_n$ 
       $\mathcal{F}_j^\omega \leftarrow t_n + \omega[j, \mu_j, \mathcal{T}]$ 
       $A_n \leftarrow A_n \cup j$ 
       $t_{\max} \leftarrow \max\{\mathcal{F}_k^\omega \mid k \in S_n\}$ 
      oblicz  $\rho[i, t, \mathcal{A}]$  dla  $t = 1, \dots, t_{\max}, i = 1, \dots, \tilde{\Psi}_R$ 
       $P_n \leftarrow \{i \mid \omega_i^- \subseteq S_n, i \notin A_n \cup S_n\}$ 
       $D_n \leftarrow \{i \mid i \in P_n, \rho[k, t^\star, \mathcal{A}] \geq \omega[i, \mu_i, \rho_k]$ 
         $t^\star = t_n, \dots, t_n + \omega[i, \mu_i, \mathcal{T}], k = 1, \dots, \tilde{\Psi}_R\}$ 
    until  $D_n = \emptyset$ 
     $n \leftarrow n + 1$ 
     $t_n \leftarrow \min\{\mathcal{F}_i^\omega \mid i \in A_{n-1}\}$ 
     $A_n \leftarrow A_{n-1} \setminus \{i \mid \mathcal{F}_i^\omega = t_n\}$ 
     $S_n \leftarrow S_{n-1} \cup \{i \mid \mathcal{F}_i^\omega = t_n\}$ 
  end while
end

```

Alg. 5.2: Równoległą procedurą budowy harmonogramu

```

input
   $(p_1, \dots, p_i, \dots, p_{\tilde{\Omega}})$  – zadane uszeregowanie czynności
begin
   $t_0 \leftarrow 1$ 
  for  $n = 1$  to  $\tilde{\Omega}$  do
     $t_n \leftarrow t_{n-1} + \min\{\tau \mid \rho[i, x, \mathcal{A}] \leq \omega[p_n, \mu_{p_n}, \rho_i], i = 1, \dots, \tilde{\Psi}_R$ 
       $x = t_{n-1} + \tau, \dots, t_{n-1} + \tau + \omega[p_n, \mu_{p_n}, \mathcal{T}], \tau \geq 0\}$ 
     $S_{p_n}^\omega \leftarrow t_n$ 
     $\rho[i, t, \mathcal{A}] \leftarrow \rho[i, t, \mathcal{A}] - \omega[p_n, \mu_{p_n}, \rho_i]$ 
    dla  $t = t_n, \dots, t_n + \omega[p_n, \mu_{p_n}, \mathcal{T}], i = 1, \dots, \tilde{\Psi}_R$ 
  end for
end

```

Alg. 5.3: Procedura budowy harmonogramu zgodna z postulatem przedstawionym w (Ulusoy i in., 2001)

W przypadku wykorzystania procedury szeregowej tworzony jest harmonogram aktywny, natomiast w przypadku równoległej harmonogram bez opóźnień. Kolisch (1996b) stwierdza, że procedura równoległa pozwala uzyskać lepsze rezultaty w zadaniach *trudnych* (o wysokim współczynniku RF i/lub niskim współczynniku RS), natomiast procedura szeregową w przypadku zadań *łatwych* (o niskim RF i/lub wysokim RS). W przypadku porównywania efektywności stosowania algorytmów metaheurystycznych zasadne wydaje się uwzględnienie postulatu, który przedstawiają Ulusoy, Sivrikaya-Şerifoğlu i Şahin (2001). Sugerują oni wykorzystanie dla reprezentacji permutacyjnej procedury umieszczającej czynności w harmonogramie zgodnie z kolejnością w uszeregowaniu, tak aby czynność rozpoczynała się nie wcześniej niż czynności znajdujące się na niższych pozycjach w uszeregowaniu. Pozwala to mieć pewność, że rozwiązanie jest ściślej związane z parametrem je definiującym, co z kolei pozwala lepiej ocenić zdolność procedury optymalizacyjnej do odnalezienia lepszych rozwiązań. Ponadto w przypadku problemów zorientowanych na optymalizację NPV, dodatkowe wstawianie czasu wolnego może prowadzić do uzyskania lepszych rozwiązań. Propozycję procedury przedstawia alg. 5.3. Istotnym elementem przemawiającym za wykorzystaniem tej procedury jest jej prostota w porównaniu z procedurą szeregową, czy równoległą, co przy konieczności ewaluacji dużej liczby parametrów może mieć wpływ na efektywność czasową metaheurystyk. Odmienne zdania są Zwikael, Cohen i Sadeh (2006), argumentując, że harmonogramy bez opóźnień ułatwiają organizację pracy menedżerów projektów, zwłaszcza w zakresie negocjacji dostępności zasobów. Kierując się jednak, jako kluczowym kryterium opłacalnością projektu i jednocześnie pomijając w badanym modelu ryzyko związanego z rosnącą w czasie niepewnością w niniejszych badaniach zastosowano procedurę przedstawioną na alg. 5.3.

5.3 Techniki poszukiwania nowych rozwiązań – zależne od problemu

Optymalizacja w ramach metaheurystyk realizowana jest poprzez dwa kierunki poszukiwania rozwiązań:

- **eksplorację** (ang. *exploration*) – polega na odnajdowaniu nowych kierunków poszukiwania, kierowania poszukiwania w nowe jeszcze nie badane obszary przestrzeni parametrów (rozwiązań). Ten rodzaj poszukiwań określany jest mianem optymalizacji globalnej lub dywersyfikacji.
- **eksploatację** (ang. *exploitation*) – polega na przeszukiwaniu wybranego fragmentu przestrzeni poszukiwań w celu odnalezienia najlepszego rozwiązania. Ten rodzaj poszukiwań określany jest mianem optymalizacji lokalnej lub intensyfikacji.

Elementy te stosowane są zwykle równolegle w różnych elementach konstrukcji metaheurystyk, z których najistotniejsze to: techniki budowy nowego rozwiązania oraz strategia poszukiwania. Większość metod korzysta z podobnych technik budowy nowego rozwiązania. Techniki te nazywane są różnie w zależności od metaheurystyki: w przypadku GA mutacją i krzyżowaniem, w przypadku SA i TS ruchem, w przypadku SS łączeniem. Ogólnie można wyróżnić dwie grupy technik: (1) operujące na jednym rozwiązaniu (2) operujące na dwóch i więcej rozwiązaniach. Zwykle za proces eksploracji odpowiedzialne

```

begin
   $i \leftarrow \text{IntRnd}(1, \tilde{\Omega})$ 
   $j \leftarrow \left\{ \text{IntRnd}(\max\{k \mid p_k \in \omega_{p_i}^\ominus\}, \min\{k \mid p_k \in \omega_{p_i}^\oplus\}) \mid i \neq j \right\}$ 
  for  $m = 1$  to  $\min\{i - 1, j - 1\}$  do  $p_m^\star \leftarrow p_m$ 
  if  $i > j$  then for  $m = j + 1$  to  $i$  do  $p_m^\star \leftarrow p_{m-1}$ 
  if  $i < j$  then for  $m = i$  to  $j - 1$  do  $p_m^\star \leftarrow p_{m+1}$ 
   $p_j^\star \leftarrow p_i$ 
  for  $m = \max\{i + 1, j + 1\}$  to  $\tilde{\Omega}$  do  $p_m^\star \leftarrow p_m$ 
end

```

Alg. 5.4: Procedura mutacji Boctora (BM)

```

begin
   $i \leftarrow \text{IntRnd}(1, \tilde{\Omega} - 1)$ 
  if  $p_{i+1} \notin \omega_{p_i}^\oplus$  then
     $P^\star \leftarrow P$ 
     $p_i^\star \leftarrow p_{i+1}$ 
     $p_{i+1}^\star \leftarrow p_i$ 
  end if
end

```

Alg. 5.5: Procedura mutacji Hartmanna (HM)

są techniki wielo-argumentowe, natomiast eksploatacja realizowana jest za pośrednictwem metod jedno-argumentowych. Dodatkowo w przypadku problemu RCPS z wieloma sposobami wykonania czynności można wyróżnić poszukiwanie rozwiązania w otoczeniu kolejnościowym oraz w otoczeniu sposobów wykonania (Bouleimen i Lecocq, 2003, Józefowska i in., 2001). Poniżej przedstawiono opis wybranych technik budowy nowych rozwiązań dla reprezentacji permutacyjnej.

5.3.1 Techniki eksploatujące – techniki jedno-argumentowe

Boctor (1996b) dla potrzeb algorytmu SA definiuje operator (określany często mianem BM – **mutacji Boctora**), który jest najpowszechniej stosowanym sposobem generowania *sąsiada*. Procedurę BM przedstawiono na alg. 5.4. Operacja polega na losowym wyborze czynności p_i w źródłowym uszeregowaniu, a następnie przesunięciu jej na losowo wybraną pozycję j pomiędzy ostatnim w uszeregowaniu poprzednikiem, a pierwszym następnikiem. W procedurę wbudowany został mechanizm zapewniający wykonalność powstałego uszeregowania $P^\star$.

Drugi z operatorów jedno-argumentowych zaproponował Hartmann (2001) dla potrzeb GA. Operator określany bywa mianem HM – **mutacji Hartmanna**. Procedurę HM przedstawiono na alg. 5.5. Operacja polega na zamianie pozycji losowo wybranej czynności p_i z czynnością następującą bezpośrednio po niej p_{i+1} o ile nie doprowadzi to do naruszenia ograniczeń kolejnościowych.

Przeszukiwanie otoczenia sposobów wykonania odbywa się poprzez zamianę sposobu wykonania losowo wybranej czynności na inny (Alcaraz i Maroto, 2001, Bouleimen i Lecocq, 2003, Hartmann, 2001, Józefowska i in., 2001).

5.3.2 Techniki eksplorujące – techniki wielo-argumentowe

Techniki wielo-argumentowe wykorzystywane są w algorytmach: GA, PLA, SS. Wszystkie operatory w tej grupie powstały dla potrzeb realizacji krzyżowania w GA i stanowią adaptację operatorów krzyżowania opracowanych dla potrzeb ogólnej reprezentacji permutacyjnej³. Nie wszystkie operatory opracowane dla potrzeb ogólnej reprezentacji permutacyjnej mogą być stosowane w rozwiązywaniu problemów

³przegląd operatorów krzyżowania dla reprezentacji permutacyjnej przedstawia Kostrubiec (2001b)

projektowych – ich realizacja może powodować powstawanie uszeregowień naruszających ograniczenia kolejnościowe.

Jednym z pierwszych operatorów stosowanych w GA było **krzyżowanie jednopunktowe** (ang. 1PX – *One-Point Crossover*) opisane już w pracy (Holland, 1975) dla reprezentacji binarnej. Hartmann (1997) dowodzi, że zastosowanie niektórych operatorów krzyżowania znanych z ogólnych problemów permutacyjnych pozwoli uzyskać uszeregowanie zachowujące ograniczenia kolejnościowe. Procedurę 1PX przedstawiono na alg. 5.6. Podobnie przystosowany operator **krzyżowania dwupunktowego** (ang. 2PX – *Two-Point Crossover*) przedstawiono na alg. 5.7.

Alcaraz i Maroto (2001) proponują nowy operator, który nazywają **krzyżowaniem kolejnościowym** (ang. PSX – *Precedence Set Crossover*). Operator ten przypomina procedury znane z operatorów krzyżowania porządkowego (OX, PBX, PMX), które opisują Davis (1985a), Goldberg i Lingle (1985), Syswerda (1991). W ramach PSX do krzyżowania wybierany jest zbiór poprzedników i następników wylosowanej czynności, podczas gdy w np. w PBX czynności do krzyżowania były wybierane losowo. Procedurę PSX przedstawiono na alg. 5.8.

Ostatnim z operatorów krzyżowania dla reprezentacji permutacyjnej z ograniczeniami kolejnościowymi jest – zgodnie z (Hartmann, 1997) – **krzyżowanie równomierne** (ang. UX – *Uniform Crossover*). Konstrukcja operatora jest identyczna jak krzyżowania z zachowaniem kolejności (ang. PPX – *Precedence Preservative Crossover*), które zaproponowali dla ogólnych problemów harmonogramowania Bierwirth, Mattfeld i Kopfer (1996)⁴. Procedurę UX przedstawiono na alg. 5.9. W pierwszym kroku tworzony jest wektor $\mathcal{V}$ o rozmiarze równym liczbie elementów w uszeregowaniu i wypełniany w sposób losowy wartościami $\{0, 1\}$. Kolejne elementy wybierane są zgodnie z wartościami wektora $\mathcal{V}$. Jeżeli na i -tej pozycji występuje wartość 0 bierany jest pierwszy niewystępujący jeszcze w rozwiązaniu P^* element z P^M , natomiast jeżeli 1 z P^F .

5.4 Symulowane wyżarzanie

Symulowane wyżarzanie (ang. SA – *Simulated Annealing*) po raz pierwszy zaproponowali Kirkpatrick, Gelatt i Vecchi (1983). Jest to procedura naśladująca proces odpuszczania, który polega na rozgrzewaniu np. metalu a następnie stopniowym jego schładzaniu celem uzyskania jak najniższego stanu energetycznego. SA stanowi rozwinięcie procedury wspinania na szczyt poprzez mechanizm akceptujący rozwiązania gorsze od bieżącego z określonym prawdopodobieństwem i co za tym idzie pozwala opuścić lokalnie optymalne fragmenty przestrzeni rozwiązań.

Na alg. 5.10 przedstawiono przykładową strukturę SA. Algorytm rozpoczyna poszukiwania od ustalonego poziomu temperatury T i losowo wybranego rozwiązania. W każdej iteracji algorytm losowo wybiera jedno rozwiązanie z sąsiedztwa $\mathcal{N}(p_{cur})$ bieżącego rozwiązania p_{cur} . Jeżeli wartość oceny nowego rozwiązania p_{new} jest lepsza, staje się ono rozwiązaniem bieżącym p_{cur} . W przeciwnym wypadku rozwiązanie p_{new} staje się rozwiązaniem bieżącym z prawdopodobieństwem określonym na podstawie rozkładu Boltzmannian $\exp\left(\frac{-\Delta}{k_B T}\right)$, gdzie Δ określa przyrost energii, a k_B jest stałą Boltzmannian. Krok ten powtarzany jest, aż do spełnienia **warunku zakończenia**, który może być określony w zależności od liczby sprawdzonych sąsiadów, bądź w zależności od przyrostów funkcji celu. Jeżeli warunek zakończenia jest spełniony aktualizowana jest bieżąca wartość temperatury T_g zgodnie z funkcją f_T . Funkcja ta zwykle określana jest w postaci $f_T(T, g) = \alpha^g T$, gdzie parametr $\alpha \in (0, 1)$. Procedura jest powtarzana, aż do **zamrożenia**, czyli uzyskania określonej niskiej wartości temperatury T_{min} .

Bouleimen i Lecocq (1998, 2000, 2003) proponują – oprócz technik specyficznych dla rozwiązania problemu RCPS – dodatkowo jedną ogólną możliwość wielokrotnego uruchomienia algorytmu. Określają ten parametr mianem łańcucha C (ang. *chains*). Każdorazowo po osiągnięciu warunku zakończenia poszukiwań algorytm SA rozpoczyna poszukiwania od losowo wybranego punktu niezależnie od poprzednio uzyskanych wyników. Parametr C nie jest wykorzystywany do kalkulacji innych parametrów lub warunków. W swoich badaniach Bouleimen i Lecocq przedstawiają wyniki dla $C \in \{1, 2, 5\}$, czyli zezwalając

⁴pomimo tego w dalszej części zachowane zostanie oznaczenie UX i nazwa *krzyżowanie równomierne* dla odróżnienia od PSX

```

begin
   $x \leftarrow \text{IntRnd}(1, \tilde{\Omega} - 1)$ 
  for  $i = 1$  to  $x$  do  $p_i^* \leftarrow p_i^M$ 
  for  $i = x + 1$  to  $\tilde{\Omega}$  do  $p_i^* \leftarrow \min\{k \mid p_k^F \notin P^*\}$ 
end

```

Alg. 5.6: Procedura krzyżowania jednopunktowego (1PX)

```

begin
   $x_1, x_2 \leftarrow \text{IntRnd}(1, \tilde{\Omega} - 1) \mid x_1 < x_2$ 
  for  $i = 1$  to  $x_1$  do  $p_i^* \leftarrow p_i^M$ 
  for  $i = x_2 + 1$  to  $\tilde{\Omega}$  do  $p_i^* \leftarrow p_i^M$ 
  for  $i = x_1 + 1$  to  $x_2$  do  $p_i^* \leftarrow \min\{k \mid p_k^F \notin P^*\}$ 
end

```

Alg. 5.7: Procedura krzyżowania dwupunktowego (2PX)

```

begin
   $x \leftarrow \text{IntRnd}(1, \tilde{\Omega} - 1)$ 
   $\mathcal{R} \leftarrow \omega_{p_x}^\ominus \cup \omega_{p_x}^\oplus$ 
  for all  $\{i \mid p_i^M \notin \mathcal{R}\}$  do  $p_i^* \leftarrow p_i^M$ 
  for all  $\{i \mid p_i^M \in \mathcal{R}\}$  do  $p_i^* \leftarrow \min\{k \mid p_k^F \notin P^*\}$ 
end

```

Alg. 5.8: Procedura krzyżowania kolejnościowego (PSX)

```

begin
  wypełnij losowo wektor  $\mathcal{V}$  o długości  $\tilde{\Omega}$  wartościami  $\{0, 1\}$ 
  for  $i = 1$  to  $\tilde{\Omega}$  do
    if  $\mathcal{V}[i] = 0$  then  $p_i^* \leftarrow \min\{k \mid p_k^M \notin P^*\}$ 
    if  $\mathcal{V}[i] = 1$  then  $p_i^* \leftarrow \min\{k \mid p_k^F \notin P^*\}$ 
  end for
end

```

Alg. 5.9: Procedura krzyżowania równomiernego (UX)

```

begin
   $g \leftarrow 0$ 
   $T_0 \leftarrow T$  założona wartość temperatury początkowej
  wybierz (wylosuj) rozwiązanie początkowe  $p_{cur}$ 
  while  $T_g > T_{min}$  do
     $g \leftarrow g + 1$ 
    while warunek zakończenia do
      wylosuj  $p_{new}$  z  $\mathcal{N}(p_{cur})$ 
      if  $\Lambda(p_{cur}) > \Lambda(p_{new})$  then  $p_{cur} \leftarrow p_{new}$ 
      else if  $\text{Rnd}_{[0,1)} < \exp\left(\frac{\Lambda(p_{cur}) - \Lambda(p_{new})}{T}\right)$  then  $p_{cur} \leftarrow p_{new}$ 
    end while
     $T_g \leftarrow f_T(T_{g-1}, g)$ 
  end while
end

```

Alg. 5.10: Ogólny schemat działania SA

na jedno-, dwu- lub pięciokrotne uruchomienie algorytmu SA. Ponadto Bouleimen i Lecocq odchodzą w procesie poszukiwania od warunku zakończenia opartego na temperaturze $T_g \leq T_{min}$ na rzecz warunków specyficznych dla sformułowanych przez siebie problemów RCPS opartych na liczbie rozwiązań nie przynoszących poprawy, całkowitej liczbie rozwiązań.

5.5 Przeszukiwanie z tabu

Podstawowe założenia algorytmu przeszukiwania z tabu⁵ (ang. TS – *Tabu Search*) przedstawili niezależnie Glover (1986) oraz Hansen (1986). Obecnie stosowaną formę opisał po raz pierwszy Glover (1989, 1990a,b). Opis procedur TS wraz z późniejszymi modyfikacjami przedstawiają m.in. Battiti i Tecchiolli (1994), Crainic, Toulouse i Gendreau (1997), Glover i Laguna (1997, 2002), Hertz, Taillard i de Werra (1997), Reeves (1995).

Słowo *tabu* (lub *taboo*) pochodzi z języka używanego przez mieszkańców wyspy Tonga w Polineezji. Oznacza ono rzecz, której nie wolno dotykać ponieważ jest święta. TS oparte jest na procedurach poszukiwania lokalnego, podobnie jak one opiera się na przeglądaniu otoczenia punktu w przestrzeni parametrów (rozwiązań) zadania. Dodatkowo utrzymywana jest pamięć krótkoterminowa zwana **listą tabu** (listą ruchów zabronionych) zawierająca rozwiązania, które nie mogą zostać zaakceptowane w kolejnych iteracjach. Lista tabu ma uchronić algorytm przed cyklicznością. Jednym z podstawowych parametrów algorytmu jest **długość listy tabu** (ang. *tabu tenure*). Im mniejszy dozwolony rozmiar listy tym większy jest nacisk na eksplorację przestrzeni rozwiązań (choć zbyt krótka lista tabu może spowodować cykliczność poszukiwań), im lista dłuższa tym intensywniej przeszukiwany jest bieżący fragment tejże przestrzeni. Taillard (1991) stosuje losowo zmienianą w procesie poszukiwania długość listy w ramach narzuconego dolnego i górnego ograniczenia. Istotnym elementem konstrukcji TS jest określenie procedury **warunkowej akceptacji** (ang. *aspiration criterion*, *aspiration level conditions*) wykorzystywanej dla rozwiązań znajdujących się na liście tabu, które pomimo tego stanowią atrakcyjny bieżący punkt dla dalszych poszukiwań. Procedura pozwala wybrać jednego z sąsiadów kierując się specyficznymi informacjami. Dodatkowo TS najczęściej wspomagane jest możliwością reinicjalizacji procesu poszukiwania.

Na alg. 5.11 przedstawiono, jak pisze Glover (1990b) jądro TS, czyli procedurę przeszukiwania z krótkookresową listą tabu, bez reinicjalizacji. W pierwszym kroku wybierane (lub losowane) jest rozwiązanie początkowe p_0 . Następnie w każdej iteracji za pomocą procedury $\mathcal{N}$ generowane jest otoczenie bieżącego punktu poszukiwań. Z otoczenia usuwane są elementy znajdujące się na liście tabu T . Następnie do zbioru przeszukiwanych rozwiązań P – określanego mianem zbioru kandydatów (ang. *Candidate List*) –

⁵czasami w tłumaczeniu używane są terminy poszukiwanie z ruchami zabronionymi, przeszukiwanie tabu (Michalewicz, 1999) lub poszukiwanie tabu

```

begin
   $g \leftarrow 0$ 
   $T \leftarrow \emptyset$ 
  wybierz (wylusuj) rozwiązanie początkowe  $p_0$ 
   $p_{\text{best}} \leftarrow p_0$ 
  while  $g < g_{\text{max}}$  do
     $g \leftarrow g + 1$ 
     $P_g \leftarrow \mathcal{N}(p_{g-1})$ 
     $P_g \leftarrow P_g \setminus T_{g-1}$ 
     $P_g \leftarrow P_g \cup \{t_i^{g-1} \mid a(t_i^{g-1}) > A, i = 1, \dots, \tilde{T}_{g-1}\}$ 
     $p_{\text{best}}^g \leftarrow \left\{ p \mid \Lambda(p) = \min_{i=1, \dots, \tilde{P}_g} \{\Lambda(p_i^g)\} \right\}$ 
    if  $\Lambda(p_{\text{best}}^g) < \Lambda(p_{\text{best}})$  then  $p_{\text{best}} \leftarrow p_{\text{best}}^g$ 
     $T \leftarrow T \cup \{p_{\text{best}}^g\}$ 
  end
end

```

Alg. 5.11: Ogólny schemat działania TS

dołączane są rozwiązania, które uzyskały warunkową akceptację – czyli te, których poziom aspiracji a jest większy od wartości granicznej A . Spośród listy P wybierany jest najlepszy kandydat p_{best}^g , jako bieżący punkt poszukiwań do kolejnej iteracji. Następnie najlepsze (globalnie) odnalezione rozwiązanie p_{best} jest aktualizowane, jeżeli w bieżącej iteracji odnaleziono lepsze rozwiązanie. Do listy tabu T dołączane jest najlepsze rozwiązanie w iteracji p_{best}^g . Procedura poszukiwania powtarzana jest g_{max} razy. Jako alternatywne rozwiązanie można ograniczyć liczbę ruchów nie poprawiających najlepszego rozwiązania, które będzie zatrzymywało procedurę w przypadku stagnacji.

5.6 Algorytmy genetyczne

5.6.1 Wprowadzenie

Podstawowym założeniem GA jest odwzorowanie naturalnych procesów ewolucji świata przyrody, które w XIX wieku opisał Karol Darwin w dziele *O pochodzeniu gatunków* (*The Origin of Species*). Darwin sformułował prawa rządzące ewolucją:

1. prawo zmienności powszechnej i bezkierunkowej,
2. prawo olbrzymiej rozrodzności organizmów,
3. prawo walki o byt,
4. prawo dziedziczenia,
5. prawo doboru naturalnego.

Z drugiej strony GA opierają się na teorii przekazywania cech genetycznych, której podstawy przedstawił Gregor Johann Mendel w 1865 roku. Zaobserwował on istnienie genów i prawa rządzące ich dziedziczeniem w procesie krzyżowania się osobników. Zainspirowany teorią Darwina i prawami genetyki w latach 70-tych XX wieku Holland (1975) opracował matematyczne podstawy funkcjonowania klasycznego algorytmu genetycznego, na które złożyła się teoria bloków budujących i twierdzenie o schematach. Klasyczny GA pracował w oparciu o reprezentację binarną. Wkrótce okazało się, że w wielu przypadkach jest to bardzo niepożądane ograniczenie. W związku z wprowadzeniem nowych sposobów kodowania wymienione wyżej dwa kluczowe elementy teorii GA były adaptowane dla kolejnych coraz bardziej wyszukanych modeli algorytmów. Kolejne algorytmy wprowadzały nowe elementy: gatunki, nisze, polimorfizm, płęć.

```

begin
   $g \leftarrow 0$ 
  utwórz populację początkową  $\mathcal{P}_0$ 
  oceń osobniki w populacji  $\mathcal{P}_0$ 
  while nie spełniony warunek zatrzymania do
     $g \leftarrow g + 1$ 
    wybierz osobniki do puli rodzicielskiej  $\mathcal{M}_g$  z populacji  $\mathcal{P}_{g-1}$ 
    przeprowadź operację rekombinacji osobników z  $\mathcal{M}_g$ 
    utwórz populację  $\mathcal{P}_g$ 
    oceń osobniki w populacji  $\mathcal{P}_g$ 
  end
end

```

Alg. 5.12: Ogólny schemat działania GA

Wszystko po to, aby w sztucznym świecie algorytmu odwzorować jak najdokładniej naturę. W poszczególnych badaniach eksponowane były różne elementy teorii ewolucji i ich sztuczne modele. W najczęściej obecnie spotykanej formie GA stanowi iteracyjną procedurę optymalizacyjną stanowiącą połączenie ogólnego modelu sztucznej ewolucji i rozmaitych procedur wspomagających związanych z typem zadania, dla którego algorytm jest projektowany. Wszystko to sprawia, że uzyskanie ścisłego modelu matematycznego (odnoszącego się do wspomnianych podstaw teorii GA) dla takiego algorytmu jest bardzo trudne lub wręcz niemożliwe. W większości badań autorzy opisują sposób funkcjonowania, natomiast zasadność dokonanych modyfikacji dowiedziona jest na drodze indukcji niezupełnej. Takie podejście zastosowano również w niniejszej pracy.

Algorytm genetyczny jest więc metaheurystyką poszukującą rozwiązania określonego problemu optymalizacyjnego na drodze kolejnych iteracji. Algorytm nie pracuje wprost na rozwiązaniu zadania, lecz na zakodowanej przestrzeni parametrów rozwiązania tegoż zadania. Rozwiązanie zadania jest reprezentowane przez strukturę zwaną **fenotypem** – jest to zbiór wartości parametrów zadania. Dla potrzeb przetwarzania przez algorytm jest on kodowany w strukturze zwanej **genotypem**. Występuje tu bezpośrednie skojarzenie z genetyką, gdzie fenotyp to zbiór cech osobnika, a genotyp to kod genetyczny osobnika, który występowanie tychże cech powoduje. W przypadku problemu harmonogramowania fenotypem będzie harmonogram, natomiast genotyp będzie zróżnicowany w zależności od przyjętego sposobu kodowania. Może być on uszeregowaniem operacji, listą reguł priorytetu, czy bezpośrednio harmonogramem. W znacznej większości GA (określanych mianem haploidalnych) genotypowi osobnika odpowiada **chromosom**, czyli ciąg (lub jakaś inna bardziej złożona struktura) **genów**. W przypadku algorytmów wykorzystujących struktury diploidalne bądź poliploidalne, genotyp osobnika będzie efektem występowania większej liczby chromosomów i określonej dominacji genów. Każdy gen warunkuje występowanie jednej lub kilku cech osobnika. Gen umieszczony jest w chromosomie na określonej pozycji zwanej **locus** (l. mn. loci). Gen może występować w chromosomie w kilku postaciach zwanych **allelami**, czyli wartościami genu.

W procesie sztucznej ewolucji osobnikowi przypisywana jest wartościowa ocena jego jakości – wartość funkcji celu, innymi słowy miara **przystosowania** osobnika. W przypadku problemu harmonogramowania będzie ona zależna od przyjętego kryterium oceny harmonogramu i będzie wyrażała wartość tego kryterium dla danego osobnika. Często zachodzi potrzeba **skalowania przystosowania**, czyli przetworzenia wartości funkcji celu na wartość przystosowania w oparciu o ustaloną funkcję. Ogólny schemat działania GA przedstawiono na rys. 5.12.

Michalewicz Michalewicz (1999) formułuje GA jako algorytm stochastyczny pracujący na zbiorze rozwiązań – zwanym **populacją** – w postaci:

$$\mathcal{P}_g = \{\mathcal{G}_1^g, \mathcal{G}_2^g, \dots, \mathcal{G}_{\mathcal{P}_g}^g\}. \quad (5.8)$$

Każdy z osobników zawiera zakodowane rozwiązanie zadania w genotypie. Każdy genotyp może być przekształcony w fenotyp, czyli rozwiązanie zadania. Jakość genotypu osobnika $\mathcal{G}_i^g$ jest oceniana poprzez procedurę ewaluacji Λ , w której każdemu osobnikowi przypisywana jest **wartość funkcji celu** λ_i zgodna z

kryterium optymalizacji. Wartość ta jest następnie w **procedurze skalowania** Δ przekształcana w **wartość przystosowania** δ_i . Ta wartość odzwierciedla siłę osobnika w dalszym procesie reprodukcji – stanowi podstawę **selekcji osobników** do **puli rodzicielskiej**, czyli zbioru osobników, które będą brały udział w dalszym procesie rozmnażania poprzez poddanie ich operacjom rekombinacji. Operatory genetyczne można podzielić na trzy rodzaje (zgodne z ich odpowiednikami w genetyce):

- **mutacja** (β) polegająca na losowej modyfikacji genotypu osobnika,
- **krzyżowanie** (α) polegające na wymianie materiału genetycznego pomiędzy dwoma lub więcej osobnikami,
- **inwersja** (γ) polegająca na odwróceniu kolejności genów w losowo wybranym fragmencie chromosomu.

Operatory genetyczne można podzielić również ze względu na liczbę osobników rodzicielskich biorących udział w operacji:

- operatory **jednoargumentowe** czyli takie, które dokonują zmiany genotypu w ramach jednego osobnika (wszystkie rodzaje mutacji i inwersji),
- operatory **wieloargumentowe** czyli te, które pozwalają na wymianę informacji genetycznej pomiędzy rodzicami dla utworzenia potomka (wszystkie rodzaje krzyżowania).

Istotność tego podziału wynika z roli jaką mają poszczególne grupy w procesie ewolucji. Zasadniczą rolę spełniają operatory wieloargumentowe, jako te które odwzorowują prawo dziedziczenia, natomiast zadaniem operatorów jednoargumentowych jest wprowadzenie elementu losowości w proces sztucznej ewolucji – losowość zmienności występuje również w przyrodzie. Po dokonaniu rekombinacji powstaje nowa populacja osobników, która poddana zostaje ocenie. W zależności od wybranej strategii promocji osobników do nowej populacji mogą być dołączane osobniki rodzicielskie, najlepszy osobnik z poprzedniej generacji lub określona liczba osobników. Tak utworzona populacja jest poddawana przekształceniom w kolejnej iteracji algorytmu.

Warunek zakończenia jest to formuła określająca kiedy $\mathbb{GA}$ ma zakończyć pracę. W praktyce wykorzystywane są trzy kryteria warunkujące zakończenie ewolucji:

- utworzenie założonej liczby populacji, czyli przeprowadzenie założonej liczby iteracji,
- uzyskanie satysfakcjonującego wyniku działania $\mathbb{GA}$, czyli odnalezienie osobnika o wartości celu na założonym poziomie,
- wykorzystanie ograniczonej ilości czasu na poszukiwanie rozwiązania.

Niemal we wszystkich badaniach związanych z harmonogramowaniem produkcji stosowane jest kryterium wykonania założonej liczby iteracji Alcaraz i Maroto (2001), Cheng i Gen (1994), Hartmann (1997, 2001), Hindi, Yang i Fleszar (2002), Özdamar (1999), Ulusoy, Sivrikaya-Şerifoğlu i Şahin (2001), Wall (1996).

5.6.2 Funkcja celu

Funkcja celu związana jest z typem zadania dla rozwiązania którego konstruowany jest $\mathbb{GA}$. Zadaniem funkcji celu jest określenie podstawy dla oceny przydatności osobnika w dalszym procesie ewolucji. Można ją sformułować jako:

$$\Lambda: \lambda_i = f(\mathcal{G}_i) \quad (5.9)$$

Funkcja celu przypisuje osobnikowi wartość odpowiadającą jego ocenie zgodnie z przyjętym kryterium optymalizacji. W przypadku problemu harmonogramowania przypisuje osobnikowi np. czas zakończenia produkcji, sumę czasów opóźnień realizacji zleceń, itp.

```

begin
   $g \leftarrow 0$ 
  utwórz populację początkową  $\mathcal{P}_0$ 
  for  $i = 0$  to  $\tilde{\mathcal{P}}_0$  do
     $\lambda_i^0 \leftarrow \Lambda(\mathcal{G}_i^0)$ 
  end
  while nie spełniony warunek zatrzymania do
     $g \leftarrow g + 1$ 
     $\delta_i^{g-1} \leftarrow \Delta(\mathcal{P}_{g-1})$ 
     $\mathcal{M}_g \leftarrow \phi(\mathcal{P}_{g-1})$ 
    while  $\tilde{\mathcal{M}}_g > 1$  do
      wylosuj  $\mathcal{R}_1$  i  $\mathcal{R}_2$  ze zbioru  $\mathcal{M}_g$ 
       $\mathcal{M}_g \leftarrow \mathcal{M}_g \setminus \{\mathcal{R}_1, \mathcal{R}_2\}$ 
      if  $\text{Rnd}_{[0,1)} \leq p_\alpha$  then  $\mathcal{P}_g^\star \leftarrow \mathcal{P}_g^\star \cup \alpha(\mathcal{R}_1, \mathcal{R}_2)$  else  $\mathcal{P}_g^\star \leftarrow \mathcal{P}_g^\star \cup \{\mathcal{R}_1, \mathcal{R}_2\}$ 
    end
    for  $i = 0$  to  $\tilde{\mathcal{P}}_g^\star$  do
      if  $\text{Rnd}_{[0,1)} \leq p_\beta$  then  $\mathcal{P}_g^\star[i] \leftarrow \beta(\mathcal{P}_g^\star[i])$ 
      if  $\text{Rnd}_{[0,1)} \leq p_\gamma$  then  $\mathcal{P}_g^\star[i] \leftarrow \gamma(\mathcal{P}_g^\star[i])$ 
    end
     $\mathcal{P}_g \leftarrow \mathcal{P}_g^\star \cup \mathcal{G}_{\text{best}}^{g-1}$ 
    for  $i = 0$  to  $\tilde{\mathcal{P}}_g$  do
       $\lambda_i^g \leftarrow \Lambda(\mathcal{G}_i^g)$ 
    end
  end
end

```

Alg. 5.13: Szczegółowy schemat działania GA

5.6.3 Skalowanie przystosowania

Przekształcenie wartości funkcji celu w miarę przystosowania osobnika ma za zadanie określić na ile dany osobnik jest przydatny (stanowi dobry materiał genetyczny) dla dalszego procesu ewolucji. W warunkach naturalnych przystosowanie osobnika określone jest przez zdolność do przeżycia i wydania na świat jak największej liczby potomstwa. Określenie sposobu przekształcania funkcji celu w miarę przystosowania jest konieczne dla zachowania równowagi pomiędzy naporem selekcyjnym i różnorodnością osobników w populacji. Nadmierne zwiększenie naporu selekcyjnego powoduje zmniejszenie różnorodności populacji, a co za tym idzie przedwczesną zbieżność procesu ewolucji. W efekcie w populacji dominują najlepiej przystosowane superosobniki, które w krótkim czasie powodują ujednolicenie materiału genetycznego. Z kolei zbyt niski poziom naporu selekcyjnego powoduje, że algorytm nie jest w stanie przeszukiwać przestrzeni rozwiązań w sposób ukierunkowany i upodabnia się do poszukiwania losowego. Wykorzystanie skalowania jest uzasadnione jedynie w przypadku mechanizmów selekcji uzależniających prawdopodobieństwo reprodukcji osobnika od wartości przystosowania (np. metoda koła ruletki). Dodatkowo skalowanie funkcji celu jest niezbędnym elementem algorytmów poszukujących rozwiązań według kryterium minimalizacji, czyli np. algorytmu genetycznego dla problemu harmonogramowania prac według kryterium minimalizacji czasu zakończenia wszystkich prac. Skalowanie jest również konieczne w przypadku możliwości wystąpienia ujemnej wartości Λ dla osobnika. Zjawisko takie może wystąpić właśnie w przypadku rozwiązywania problemów RCPS według kryterium NPV.

Ogólnie funkcje skalowania można zapisać, jako:

$$\Delta: \delta_i = f(\lambda_1, \dots, \lambda_j, \dots, \lambda_k) \quad (5.10)$$

5.6.4 Selekcja osobników

Po określeniu wartości funkcji przystosowania osobników w populacji algorytm przechodzi do procedury selekcji osobników do następnej generacji. Zadaniem procedury jest wybranie z populacji $\mathcal{P}_{t-1}$ osobników do procesu dalszej reprodukcji. Osobniki te są umieszczane w puli rodzicielskiej $\mathcal{M}_t$.

$$\phi: \mathcal{M}_t = f(\mathcal{P}_{t-1}) \quad (5.11)$$

Selekcja metodą koła ruletki

Selekcja metodą koła ruletki (ang. *roulette wheel selection*) nazywana również wyborem losowym z powtórzeniami, jest najpopularniejszym sposobem doboru osobników do puli rodzicielskiej. Szansa umieszczenia osobnika w puli rodzicielskiej zależy bezpośrednio od wartości jego przystosowania. Im lepiej przystosowany osobnik w tym większą ilość potomków będzie posiadał, co zgodne jest z założeniami teorii ewolucji Darwina. Każdemu osobnikowi przypisane jest prawdopodobieństwo wylosowania, proporcjonalne do jego wartości przystosowania, określone jako:

$$p_i = \frac{\delta_i}{\sum_{j=1}^{\mathcal{P}_{t-1}} \delta_j} \quad (5.12)$$

Koło losowania podzielone jest na wycinki, których liczba odpowiada liczbie osobników w populacji $\mathcal{P}_{t-1}$, a wielkość każdego z wycinków jest proporcjonalna do prawdopodobieństwa wylosowania poszczególnych osobników. Liczba losowań odpowiada założonej wielkości puli rodzicielskiej. Procedura losowania przedstawiono na alg. 5.14.

Selekcja turniejowa

Selekcja turniejowa polega na losowaniu określonej liczby osobników, a następnie promowaniu do puli rodzicielskiej osobnika najlepiej przystosowanego. Liczba losowań (turniejów) odpowiada wielkości puli

```

begin
  for  $i = 1$  to  $\tilde{\mathcal{M}}_t$  do
     $u \leftarrow \text{Rnd}_{[0,1)}$ 
     $k \leftarrow 0$ 

    repeat  $k \leftarrow k + 1$  until  $\sum_{j=1}^k p_k > u$ 

     $\mathcal{M}_t \leftarrow \mathcal{M}_t \cup \{\mathcal{G}_k^{t-1}\}$ 
  end
end

```

Alg. 5.14: Procedura losowania według koła ruletki

```

parametry
   $\zeta$  – wielkość turnieju
begin
  for  $i = 1$  to  $\tilde{\mathcal{M}}_{t+1}$  do
     $\mathcal{Z} = \emptyset$ 
    repeat
      wylosuj  $o$  ze zbioru  $\{1, \dots, \tilde{\mathcal{P}}_t\}$ 
       $\mathcal{Z} = \mathcal{Z} \cup \{o\}$ 
    until  $\tilde{\mathcal{Z}} = \zeta$ 
     $m \leftarrow \min \left\{ j \mid \delta_j^t = \max_{n=1, \dots, \zeta} \{\delta_{\mathcal{Z}_n}^t\} \right\}$ 
     $\mathcal{M}_{t+1} \leftarrow \mathcal{M}_{t+1} \cup \{\mathcal{G}_m^t\}$ 
  end
end

```

Alg. 5.15: Procedura selekcji turniejowej

rodzicielskiej. W literaturze opisywane są modyfikacje modelu selekcji turniejowej z wykorzystaniem mechanizmu symulowanego wyżarzania. Każdy z osobników ma taką samą szansę wylosowania do turnieju:

$$p_i = \frac{1}{\tilde{\mathcal{P}}_{t-1}} \quad (5.13)$$

Na alg. 5.15 przedstawiono procedurę selekcji turniejowej.

5.7 Przeszukiwanie rozproszone

Źródłem procedury przeszukiwania rozproszonego (ang. *SS* – *Scatter Search*) jest metoda opracowana dla redukcji liczby ograniczeń w problemach programowania 0-1, którą przedstawia Glover (1965). Metoda ta redukuje liczbę ograniczeń w modelu poprzez ich zastąpienie nową nierównością (ang. *surrogate constraint*). *SS* opiera się na dwóch zasadniczych elementach: (1) łączy fragmenty odnalezionych uprzednio rozwiązań tworząc rozwiązanie o cechach, których nie posiadało żadne z rozwiązań źródłowych, (2) wykorzystuje pomocnicze heurystyki zarówno dla generowania nowych rozwiązań, jak i wyboru rozwiązań do łączenia. Opis procedury *SS* oraz jej uogólnionej formy *PR* (ang. *Path Relinking*) przedstawiają m.in. Glover (1999, 2003), Glover, Laguna i Martí (2000, 2002a,b, 2003a,b), Laguna (2002), Laguna i Armentano (2003), Martí, Laguna i Glover (2003b). Algorytm *SS* zastosowano w harmonogramowaniu problemów typu przepływowego (Jain i Meeran (1998b), Reeves i Yamada (1998), Yamada i Reeves (1997, 1998)) oraz ogólnego (Jain i Meeran (1998a)). Dla intensyfikacji poszukiwań stosowane są procedury *TS* lub *LS*, natomiast dywersyfikacja realizowana jest za pomocą wymiany części populacji na zupełnie nowe (jak najbardziej różnorodne) rozwiązania. Campos, Laguna i Martí (2003), Martí, Laguna i Campos (2003a) przedstawiają procedurę *SS* dla problemów o charakterze permutacyjnym dodatkowo

wzmacniając proces przeszukiwania procedurą przebudowy zbioru referencyjnego. García-López, Melián, Moreno-Pérez i Moreno-Vega (2003) proponują równoległe $\mathbb{SS}$ poprzez stosowanie równoległe procedur ulepszania osobników, natomiast Beausoleil (2001) przedstawia zastosowanie $\mathbb{SS}$ w rozwiązywaniu problemów wielokryterialnych.

Schemat procedury $\mathbb{SS}$ opartej na rozwiązaniach, które dla problemów permutacyjnych zaproponowali Campos, Laguna i Martí (2003) przedstawiono na alg. 5.16. W pierwszym kroku tworzona jest **populacja początkowa** $\mathcal{P}_0$ składająca się z założonej $\tilde{P}$ liczby osobników. Osobniki generowane są za pomocą systematycznej procedury zapewniającej ich różnorodność (jakość rozwiązań nie jest istotna na tym etapie). Następnie osobniki ze zbioru $\mathcal{P}_0$ poddawane są **procedurom ulepszenia** (Campos, Laguna i Martí stosują procedury TS oraz LS) oznaczonym jako $\mathcal{I}$, tak aby móc rozpocząć właściwe poszukiwania od populacji o *rozsądnej* jakości. Na podstawie populacji początkowej tworzony jest **zbiór referencyjny** (ang. *Reference Set*) oznaczony jako $\mathcal{RS}$, który stanowi odpowiednik populacji w GA. Do zbioru $\mathcal{RS}$ wybieranych jest b_1 (Campos, Laguna i Martí stosują liczbę $b/2$) najlepszych osobników z $\mathcal{P}_0$ oraz następnie zbiór $\mathcal{RS}$ jest uzupełniany osobnikami z pozostałej części $\mathcal{P}_0$ aż do uzyskania liczebności b . Osobniki do uzupełnienia są wybierane według kryterium maksymalizacji minimalnej odległości od osobników zawartych w $\mathcal{RS}$. Następnie zerowany jest licznik globalnych popraw najlepszego rozwiązania g . W kolejnych iteracjach zgodnie z procedurą $\sigma()$ losowane (wybierane) są elementy ze zbioru $\mathcal{RS}$, tak aby co najmniej jeden z nich nie był wcześniej używany w **operacji łączenia** rozwiązań $\alpha()$. Ponieważ operator $\alpha()$ jest projektowany tak, aby nowo powstałe rozwiązania składały się z fragmentów rozwiązań źródłowych operowanie kilkukrotnie na tym samym rozwiązaniu znacznie obniżałoby efektywność poszukiwań. W wyniku operacji łączenia powstają nowe osobniki zapisywane w **zbiorze próbnym** (ang. *Trial Set*) oznaczonym jako $\mathcal{T}$. Każdy z osobników ze zbioru $\mathcal{T}$ poddawany jest procedurom ulepszenia $\mathcal{I}$. Następnie zbiór $\mathcal{RS}$ jest poddawany **statycznej aktualizacji**, która polega na wybraniu b najlepszych osobników z $\mathcal{RS} \cup \mathcal{T}$. Jeżeli w zaktualizowanym zbiorze $\mathcal{RS}$ nie ma żadnego z rozwiązań ze zbioru $\mathcal{T}$ procedura przechodzi do **etapu dywersyfikacji**, który polega na usunięciu połowy najgorszych rozwiązań ze zbioru $\mathcal{RS}$ i uzupełnieniu go do liczebności b nowymi zróżnicowanymi osobnikami. Podobnie jak w pierwszym kroku tworzona jest populacja $\mathcal{P}_0$ zróżnicowanych osobników o liczebności $\tilde{P}$, które to osobniki są poddawane procedurom ulepszenia. Następnie ze zbioru $\mathcal{P}_0$ wybieranych jest b_2 (w badaniach, które opisują Campos, Laguna i Martí (2003) jest to wielkość równa $b/2$) osobników najbardziej zróżnicowanych względem rozwiązań w zbiorze $\mathcal{RS}$ i są one dołączane do zbioru odniesienia $\mathcal{RS}$. Przed dywersyfikacją aktualizowany jest najlepszy odnaleziony osobnik s_{best} . W tym celu ze zbioru $\mathcal{RS}$ wybierany jest najlepszy osobnik s_{cur} . Jeżeli wartość funkcji celu s_{cur} jest lepsza od s_{best} licznik globalnych popraw g jest zerowany, a s_{best} zastępowany przez s_{cur} . W przeciwnym wypadku licznik g jest zwiększany o 1. Jeżeli liczba iteracji, które nie doprowadziły do poprawy najlepszego osobnika wyniesie g_{max} procedura jest zatrzymywana z uwagi na stagnację procesu przeszukiwania. Jako rozwiązanie przyjmowane jest s_{best} .

5.8 Algorytm uczenia populacji

Algorytm uczenia populacji (ang. PLA – *Population Learning Algorithm*) jest populacyjną metaherytyką opartą na analogii do systemu edukacyjnego, którą zaproponował Jędrzejowicz (1999) pod nazwą *Social Learning Algorithm*. W konstrukcji PLA wykorzystano następujące cechy charakterystyczne systemu edukacji: (1) naukę rozpoczyna duża liczba osobników, (2) osobniki biorą udział w kolejnych, coraz trudniejszych i bardziej złożonych procedurach nauki, (3) liczba osobników uczestniczących w kolejnych etapach nauki maleje (4) osobniki mogą uczyć się samodzielnie lub wymieniać wiedzę między sobą. W efekcie niewielka liczba najlepiej wykształconych dochodzi do końca procesu nauczania. Badania zastosowania PLA z reprezentacją permutacyjną w problemach harmonogramowania przedstawiają Barbucha, Forkiewicz, Jędrzejowicz i Ratajczak (2001), Jędrzejowicz i Jędrzejowicz (2003), Jędrzejowicz i Ratajczak (2003).

Strukturę PLA przedstawiono na alg. 5.17. W pierwszym kroku tworzona jest losowo (lub częściowo z wykorzystaniem metod heurystycznych) tworzona jest populacja osobników $\mathcal{P}_0$ o założonym rozmiarze $\tilde{P}_0$. W kolejnych etapach procesu uczenia populacji każdy z osobników poddawany jest **procedurom nauki** (poprawy) $\mathcal{L}_g$. Są to zwykle szczegółowo zaprojektowane procedury poszukiwania lokalnego oparte

```

begin
  repeat
    generuj zdywersyfikowane rozwiązanie  $x$ 
     $x \leftarrow \mathcal{I}(x)$ 
    if  $x \notin \mathcal{P}_0$  then  $\mathcal{P}_0 \leftarrow \mathcal{P}_0 \cup \{x\}$ 
  until  $\tilde{\mathcal{P}}_0 = \tilde{\mathcal{P}}$ 
  zbuduj zbiór referencyjny  $\mathcal{RS}$  wybierając  $b_1$  najlepszych rozwiązań ze zbioru  $\mathcal{P}_0$ 
   $\mathcal{P}_0 \leftarrow \mathcal{P}_0 \setminus \mathcal{RS}$ 
   $s_{\text{best}} \leftarrow \left\{ s_k \mid \Lambda(s_k) = \min_{i=1, \dots, |\mathcal{RS}|} \{\Lambda(s_i)\} \right\}$ 
   $g \leftarrow 0$ 
  repeat
    for  $i = 1$  to  $\tilde{\mathcal{P}}_0$  do  $d_i \leftarrow \min_{k=1, \dots, |\mathcal{RS}|} \{\delta(\mathcal{P}_0(i), \mathcal{RS}(k))\}$ 
    repeat
       $\mathcal{RS} \leftarrow \mathcal{RS} \cup \left\{ \mathcal{P}_0(i) \mid d_i = \max_{k=1, \dots, \tilde{\mathcal{P}}} \{d_k \mid \mathcal{P}_0(k) \notin \mathcal{RS}\}, i = 1, \dots, \tilde{\mathcal{P}} \right\}$ 
    until  $|\mathcal{RS}| = b$ 
     $Stop \leftarrow \text{FAŁSZ}$ 
    repeat
       $\mathcal{T} \leftarrow \sigma(\mathcal{RS})$ 
       $\mathcal{T} \leftarrow \alpha(\mathcal{T})$ 
       $t_i \leftarrow \mathcal{I}(t_i), \quad i \in 1, \dots, \tilde{\mathcal{T}}$ 
      if  $\mathcal{T} \subset \mathcal{RS}$  then  $Stop \leftarrow \text{PRAWDA}$ 
      aktualizuj  $\mathcal{RS}$  wybierając  $b$  najlepszych rozwiązań ze zbioru  $\mathcal{T} \cup \mathcal{RS}$ 
    until  $Stop$ 
     $s_{\text{cur}} \leftarrow \left\{ s_k \mid \Lambda(s_k) = \min_{i=1, \dots, |\mathcal{RS}|} \{\Lambda(s_i)\} \right\}$ 
    if  $\Lambda(s_{\text{cur}}) < \Lambda(s_{\text{best}})$  then
       $s_{\text{best}} \leftarrow s_{\text{cur}}$ 
       $g \leftarrow 0$ 
    else
       $g \leftarrow g + 1$ 
    end if
    usuń  $b_2$  najgorszych osobników ze zbioru  $\mathcal{RS}$ 
  repeat
    generuj zdywersyfikowane rozwiązanie  $x$ 
     $x \leftarrow \mathcal{I}(x)$ 
    if  $x \notin \mathcal{P}_0$  then  $\mathcal{P}_0 \leftarrow \mathcal{P}_0 \cup \{x\}$ 
  until  $\tilde{\mathcal{P}}_0 = \tilde{\mathcal{P}}$ 
  until  $g = g_{\text{max}}$ 
end

```

Alg. 5.16: Ogólny schemat działania SS

begin $g_{\max}$ – liczba etapów naukiokreśl procedury uczenia $\mathcal{L}_g$, $g = 1, \dots, g_{\max}$ określ procedury selekcji $\mathcal{S}_g$, $g = 1, \dots, g_{\max}$ generuj populację początkową $\mathcal{P}_0$ **for** $g = 1$ **to** $g_{\max}$ **do** $\mathcal{P}_g \leftarrow \mathcal{L}_g(\mathcal{P}_{g-1})$ $\lambda_k^g \leftarrow \Lambda(\mathcal{G}_k^g), \quad k = 1, \dots, \tilde{\mathcal{P}}_g$ $\mathcal{P}_g \leftarrow \mathcal{S}_g(\mathcal{P}_g)$ **end for**
$$\mathcal{G}_{\text{best}} \leftarrow \left\{ \mathcal{G}_i^{g_{\max}} \mid \lambda_i^{g_{\max}} = \min_{k=1, \dots, \tilde{\mathcal{P}}_{g_{\max}}} \{ \lambda_k^{g_{\max}} \} \right\}$$
end

Alg. 5.17: Ogólny schemat działania PLA

na metodach heurystycznych, bądź na prostych metaheurystykach. W kolejnych iteracjach procedury są coraz bardziej złożone i wymagają coraz większej ilości czasu obliczeń. Po etapie uczenia następuje ocena wartości funkcji celu λ_i^g dla każdego osobnika, a następnie zgodnie z **procedurą selekcji** $\mathcal{S}_g$ wybierane są zwykle najlepsze osobniki (rokujące odnalezienie najlepszych rozwiązań w kolejnych etapach). Na ich podstawie tworzona jest populacja do kolejnego etapu nauki. Osobniki mogą się uczyć **samodzielnie** lub poprzez **wymianę informacji** (podobnie jak w przypadku GA – mutacja i krzyżowanie). Jako rozwiązanie przyjmowany jest najlepszy osobnik z ostatniej populacji.

Kolejne etapy nauki wymagają szczegółowego określenia (zaprojektowania) procedur nauki (zwykle odmiennych dla różnych etapów) oraz procedur promocji osobników do kolejnych etapów edukacji (które również mogą się zmieniać w kolejnych iteracjach). W przypadku reprezentacji permutacyjnej procedury nauki samodzielnej mogą być oparte na technikach jedno-argumentowych w początkowych etapach edukacji, a kolejno przechodzić poprzez proste metody poszukiwania lokalnego, aż po proste metaheurystyki (np. SA, TS). Wymiana informacji pomiędzy osobnikami odbywać będzie się na drodze technik wielo-argumentowych. Dywersyfikacja poszukiwań w PLA realizowana jest poprzez wygenerowanie w pierwszym etapie dużej liczby osobników w porównaniu z pozostałymi metaheurystykami, co ma pozwolić na rozpoczęcie przeszukiwania z możliwie rozległego obszaru przestrzeni rozwiązań. W odróżnieniu od pozostałych procedur w przypadku PLA liczba etapów (iteracji) jest stosunkowo niewielka, co pozwala na efektywną czasowo realizację pierwszego założenia.

Analiza wyników eksperymentów obliczeniowych

Niniejszy rozdział zawiera wyniki badań eksperymentalnych skuteczności wybranych metaheurystyk opisanych w rozdziale 5. Z uwagi na złożoność obliczeniową badanie efektywności wybranych metod przeprowadzono za pomocą eksperymentów obliczeniowych, które są jedną z podstawowych metod oceny algorytmów heurystycznych (Błażewicz, 1986). Badanie tego rodzaju pozwala na przeanalizowanie właściwości badanych algorytmów, wpływu ich parametrów oraz parametrów problemu na przeciętnie uzyskiwane wyniki. W rozdziale przedstawiono: zasady konstrukcji zestawu problemów testowych, plan eksperymentu wraz ze środowiskiem obliczeniowym i metodą analizy wyników oraz wyniki eksperymentów wraz z analizą i wnioskami.

6.1 Założenia

6.1.1 Analiza dostępnych zestawów problemów testowych

Istnieje kilka zestawów problemów, na podstawie których przeprowadzane są badania porównawcze efektywności metod optymalizacji harmonogramów realizacji projektów. Analizę wybranych zestawów pod kątem topologii generowanych sieci przedstawiają Tavares, Ferreira i Coelho (2002). Kluczowym problemem występującym przy generowaniu problemów jest zapewnienie możliwie najpełniejszej reprezentacji przestrzeni wszystkich instancji określonego modelu. Do najpopularniejszych generatorów można zaliczyć:

- **ProGen** – najpowszechniej stosowany w badaniach losowy generator dla problemów z jednym i wieloma sposobami realizacji czynności, który zaprezentowali Kolisch i Sprecher (1996), Kolisch, Sprecher i Drexel (1995). Generator ten wykorzystuje reprezentację w postaci sieci AON. ProGen pozwala generować problemy o założonym rozmiarze z założonym współczynnikiem złożoności sieci (ang. *CNC* – *Coefficient of Network Complexity*)¹ obliczonym jako stosunek liczby nieredundantnych łuków do liczby wierzchołków sieci zgodnie z definicją, którą dla sieci typu AON przedstawił Davis (1975). Generator umożliwia uwzględnienie trzech rodzajów zasobów: odnawialnych, nieodnawialnych i podwójnie ograniczonych (jako kombinacji jednego zasobu odnawialnego i jednego nieodnawialnego). Dla oceny zapotrzebowania na zasoby stosowany jest współczynnik zasobów (ang. *RF* – *Resource Factor*), który określa liczbę zasobów z puli przydzielanych do jednej czynności oraz siła zasobu (ang. *RS* – *Resource Strength*)² określająca ścisłość ograniczeń dla danego

¹Kolisch, Sprecher i Drexel (1992, 1995) współczynnik ten oznaczają jako *C*, Kolisch i Sprecher (1996) oznaczają go jako *NC* (ang. *Network Complexity*), Ulusoy, Sivrikaya-Şerifoğlu i Şahin (2001) jako *CPX* (ang. *Complexity Ratio*), natomiast Demeulemeester, Vanhoucke i Herroelen (2003), Reyck i Herroelen (1996) oznaczają ten sam współczynnik jako *CNC* odwołując się do źródłowego opracowania (Pascoe, 1966), w którym zaproponowano po raz pierwszy tenże miernik dla reprezentacji w postaci sieci AOA. Terminem *Coefficient of Network Complexity* posługują się również Davis (1973), Kaimann (1974, 1975) definiując go jednakże odmiennie.

²Pierwotną definicję współczynnika *RS* podał Cooper (1976). Kolisch, Sprecher i Drexel (1992, 1995) wprowadzają nową formę *RS*, która jest obecnie powszechnie stosowana (m.in. Herroelen, Reyck i Demeulemeester (1998), Reyck i Herroelen (1996), Schwindt (1995, 1998)). Demeulemeester, Vanhoucke i Herroelen (2003) dokonują dalszej modyfikacji *RS*, która ma gwarantować wykonalność generowanego problemu harmonogramowania, czego przy małych wartościach *RS* nie zapewnia stosowanie definicji, którą zaproponowali Kolisch, Sprecher i Drexel (1995).

typu zasobu. Kolisch i Sprecher przedstawia wygenerowane z pomocą ProGen zestawy modeli z jednym i wieloma sposobami wykonania czynności. Schwindt (1995) przedstawia modyfikację ProGen umożliwiającą generowanie problemów ze względnymi ograniczeniami czasowymi w postaci ProGen/*max*. Jednocześnie uznając w świetle wyników badań, które przedstawiają Reyck i Herroelen (1996) CNC jako niewystarczający dla oceny *trudności* sieci, jako dodatkową miarę wprowadza RT (ang. *Estimator for the Restrictiveness*) na podstawie definicji, którą przedstawił Thesen (1977). Schwindt (1998) jako parametr regulujący złożoność sieci wybiera OS (ang. *Order Strength*) zdefiniowany jako stosunek liczby wszystkich relacji pomiędzy czynnościami (z wyłączeniem relacji od węzła źródłowego i bezpośrednio do końcowego jeżeli są to węzły pozorne) do wszystkich teoretycznie możliwych relacji, który opisał po raz pierwszy Mastor (1970). Zauważa jednocześnie, że mierniki RT i OS w istocie określają ten sam aspekt złożoności sieci co również potwierdzają Herroelen i Reyck (1999). Jednocześnie Schwindt wprowadza rozgraniczenia trzech rodzajów zestawów problemów porównawczych: (1) dla minimalizacji czasu trwania, (2) dla wyrównywania obciążeń zasobów oraz (3) z przepływami pieniężnymi dla maksymalizacji NPV. W efekcie Kolisch, Schwindt i Sprecher (1999) przedstawiają zbiór problemów określanych mianem PSPLIB, wygenerowany za pomocą ProGen/*max* zawierający problemy o zróżnicowanym rozmiarze i ograniczeniach zasobowych podzielone na trzy kierunki optymalizacji według sugestii, którą przedstawił Schwindt (1998). Drexl, Nissen, Patterson i Salewski (2000) dokonują dalszej rozbudowy funkcji generatora ProGen/*max* uwzględniając możliwość generowania modeli z zasobami częściowo odnawialnymi – określają go mianem ProGen/ πx .

- **DAGEN** – generator problemów oparty na sieci AOA, który zaproponowali Agrawal, Elmaghraby i Herroelen (1996). Główny nacisk położony jest w nim na topologię generowanych sieci, kwestia ograniczeń zasobowych potraktowana jest drugoplanowo. Topologia sieci oceniana jest na podstawie wskaźnika CI (ang. *Complexity Index*) zgodnie z koncepcją redukcji złożoności sieci (ang. *Complexity Reduction*), którą przedstawili Bein, Kamburowski i Stallmann (1992). Sieć typu AOA oceniana jest na podstawie minimalnej liczby węzłów, które należy zredukować dla uzyskania sieci szeregowo-równoległej. Zapotrzebowanie na zasoby oraz koszty generowane jest z rozkładów równomiernych.
- **RanGen** – najnowszy z generatorów dla reprezentacji w postaci sieci AON, który opisali Demeulemeester, Vanhoucke i Herroelen (2003), Vanhoucke, Demeulemeester i Herroelen (2000). Autorzy zauważają, że ocenianie złożoności sieci na podstawie jednego parametru jest niewystarczające, gdyż bada on jedynie wybrany aspekt złożoności i możliwe jest uzyskanie mocno zróżnicowanych sieci o zbliżonej wartości wybranego miernika. Autorzy proponują generowanie sieci o jednocześnie założonych współczynnikach OS i CI^3 co ma zagwarantować możliwość uzyskania reprezentatywnego zestawu problemów. RanGen nie umożliwia generowania problemów ze względnymi ograniczeniami czasowymi. Dla generowania zapotrzebowania na zasoby autorzy poza RF i RS wprowadzają nowy współczynnik RU (ang. *Resource Use*) – przyjmujący wartość pomiędzy 0, a całkowitą liczbą zasobów – określający ile rodzajów zasobów będzie wykorzystywanych dla realizacji jednej czynności (w odróżnieniu od RF, który definiuje średnią liczbę przypisanych zasobów). Główny nacisk w RanGen położono na problem generowania sieci o zróżnicowanej topologii i wspólnych założonych wartościach parametrów. Sposób przypisywania zasobów podobny jest do wcześniejszych rozwiązań. W przypadku problemów wielomodalnych autorzy proponują generowanie różnej wielkości zapotrzebowania na zasoby (wylosowane lecz tego samego rodzaju w ramach czynności) według czterech rodzajów zależności: losowych, wklęsłych, liniowych i wypukłych w przeciwieństwie do procedury ProGen/*max*, która dla różnych sposobów wykonania czynności losowo przypisuje różne zasoby z puli i losowe wielkości zapotrzebowania. Sposób zaproponowany w procedurze RanGen pozwala uzyskać jedynie efektywne sposoby wykonania czynności⁴.

³procedurę przekształcenia sieci AON w odpowiadającą jej sieć AOA z minimalnym współczynnikiem CI, którą zaproponowali Kamburowski, Michael i Stallmann (1992) opisują Reyck i Herroelen (1996)

⁴sposób wykonania czynności określamy mianem nieefektywnego jeżeli skrócenie czasu realizacji czynności możliwe jest w ramach wykorzystania nie większej liczby zasobów

Powszechnie stosowany w badaniach efektywności procedur optymalizacyjnych jest również zestaw 110 problemów klasy RCPS z jednym sposobem wykonania czynności i zasobami odnawialnymi, który przedstawia Patterson (1984). Problemy zawierają od 5 do 49 czynności. Zestaw ten nie został wygenerowany losowo – stanowi zbiór problemów z różnych źródeł (m.in. Davis (1969), Davis i Patterson (1975), Patterson i Huber (1974), Talbot i Patterson (1978)). Kolisch, Sprecher i Drexel (1995) dowodzą, że problemy z tego zbioru są łatwe i istnieją problemy o mniejszej liczbie czynności, które są trudniejsze z punktu widzenia optymalizacji.

Zarówno w przypadku procedury DAGEN, jak i RanGen brak jest powszechnie stosowanego zestawu problemów testowych. ProGen/max wymaga określenia dużej liczby parametrów obejmujących m.in.: maksymalną liczbę poprzedników, maksymalną liczbę następników, minimalną i maksymalną liczbę węzłów początkowych, minimalną i maksymalną liczbę węzłów końcowych, co w efekcie znacznie ogranicza warunek równomiernej reprezentacji przestrzeni sieci. Dodatkowo poprzez uwzględnienie jedynie założonej wielkości estymatora RT, ogranicza możliwość wygenerowania problemów o założonym stopniu trudności sieci.

6.1.2 Opis i analiza badanych problemów

W związku z powyższymi ograniczeniami istniejących zestawów problemów RCPS niniejsze badania oparto na zestawie instancji wygenerowanych na podstawie fragmentu biblioteki PSPLIB. W wybranym zestawie problemów składających się z 10, 30, 60 i 90 czynności zawartych w zbiorach js10.mm, js30.sm, js60.sm, js90.sm dokonano następujących modyfikacji:


- Ograniczenia czasowe w postaci minimalnych opóźnień wygenerowano w sposób oparty na procedurze ProGen/max (opis w Schwindt (1995, s. 36-38)). Występowanie opóźnień potraktowano jako sposób doprecyzowania istniejących już relacji w wygenerowanych sieciach, dla zachowania predefiniowanej w ramach biblioteki PSPLIB złożoności sieci wyrażonej współczynnikiem NC. Opóźnienie losowane jest z wykorzystaniem parametru dolnego ($SL_{\min}$) ograniczenia w postaci:

$$ZR_{i \rightarrow j}^{\min} = SL_{\min} * \min_{m=1, \dots, M_i^w} \{\omega[i, m, \mathcal{T}]\} \quad (6.1)$$

- Ograniczenia czasowe w postaci maksymalnych opóźnień zrelaksowano w badanych instancjach przyjmując:

$$ZR_{i \rightarrow j}^{\max} = \infty \quad (6.2)$$

- Informacje o zapotrzebowaniu na zasoby generowane były zgodnie z procedurą RanGen (Demeulemeester i in., 2003, s. 35–36). Generator ProGen/max w przypadku modeli wielomodalnych, dla każdego sposobu wykonania czynności wybiera losowo zasoby, których zaangażowanie jest wymagane i również losowo określa poziom zapotrzebowania na te zasoby. W efekcie powoduje to możliwość powstania nieefektywnych sposobów realizacji czynności, które będą eliminowane w procedurze wstępnej. Ponadto sytuacja, w której czynność może być wykonana przez dowolną kombinację zasobów z puli jest bardzo rzadko obserwowana w rzeczywistych projektach, zwykle zmiana czasu wykonania czynności spowodowana jest zwiększeniem liczby jednostek zasobów zaangażowanych w realizację czynności. W procedurze ProGen/max możliwe jest uzyskanie zmniejszonego zaangażowania liczby zasobów (czy ich jednostek) pozwalającego na realizację czynności w krótszym czasie, które to zjawisko nie znajduje uzasadnienia w rzeczywistych projektach. W procedurze RanGen w ramach zależności czas–zasób dla każdej czynności losowo wybierane są zasoby potrzebne dla jej realizacji (zgodnie z parametrami RF, RU). Następnie zapotrzebowanie generowane jest zgodnie z określonym kształtem funkcji (losowy, wklęsły, liniowy lub wypukły) dla kolejnych sposobów wykonania czynności. W efekcie wraz ze zwiększaniem zaangażowania zasobów uzyskujemy skrócenie czasu realizacji i wzrost kosztów.
- Informacje o dostępności zasobów generowane są w podobny sposób zarówno w ProGen/max, jak i RanGen, pozwalając na zachowanie założonej wielkości parametru RS zarówno dla zasobów



Rys. 6.1: Parametry składników kosztów w badanych problemach $\mathbb{RCPS}$

odnawialnych jak i nieodnawialnych. Podobnie jak w bibliotece PSPLIB przyjęto dla zasobów odnawialnych $\bar{\mathbb{RS}}^o \in \{0,3; 0,5; 0,7\}$ i dla zasobów nieodnawialnych $\bar{\mathbb{RS}}^v \in \{0,3; 0,5; 0,7\}$. W efekcie uzyskano 9 kombinacji par parametrów ścisłości ograniczeń zasobowych $(\bar{\mathbb{RS}}^o, \bar{\mathbb{RS}}^v)$.

- Koszty stałe realizacji czynności i projektu oraz koszty użycia zasobów generowane będą według rozkładu równomiernego z określonego przedziału zgodnie z rys. 6.1. Liczba współczynników kosztów zmiennych losowana będzie dla każdego rodzaju zasobu z zakresu $[1, 3]$. Natomiast współczynniki kosztów stałych dla czynności z zakresu $[1, 3]$ oraz dla zasobów jeden ze współczynników, co pozwoli na uzyskanie możliwie zróżnicowanych profili kosztów całkowitych realizacji projektów $\mathcal{E}_i^\pi$.
- Przychody z realizacji projektu obliczane będą z wykorzystaniem modelu płatności całość po zakończeniu. Kwota przychodu po zakończeniu ostatniej czynności określona będzie na podstawie kosztów całkowitych wykonania projektu powiększonych o oczekiwaną marżę w wartościach bieżących. Dla projektu określony jest współczynnik zyskowności (ang. *profit margin*) względem najkosztowniejszego sposobu wykonania w wartościach bieżących na poziomie 0,5.

W efekcie uzyskano zbiór 270 instancji problemów klasy $\mathbb{RCPS}$, zgodnych z modelem sformułowanym w p. 4 o zróżnicowanej topologii sieci, różnym stopniu ograniczeń zasobowych.

6.1.3 Opis planu eksperymentów

Dla zbadania prawdziwości hipotez badawczych przedstawionych w rozdziale 1 przeprowadzono badania symulacyjne na wybranej grupie problemów harmonogramowania klasy $\mathbb{RCPS}$ zgodnych z zapisem modelu przedstawionym w p. 4.1.

Plan eksperymentów oparty został na następujących założeniach:

- badania przeprowadzono na grupie problemów wygenerowanej zgodnie z opisem w p. 6.1.2,

Miernik	Źródło	Definicja
CNC	(Davis, 1975)	$\frac{\sum_{i,j \in \Omega} \mathbb{Z}\mathbb{R}_{i \rightarrow j}^{\text{imi}}}{\tilde{\Omega}}$
OS	(Mastor, 1970)	$\frac{\sum_{i,j \in \Omega} \mathbb{Z}\mathbb{R}_{i \rightarrow j}^{\text{all}}}{\tilde{\Omega}(\tilde{\Omega} - 1)/2}$
RT	(Schwindt, 1995)	$\frac{2 \sum_{i,j \in \Omega} \mathbb{Z}\mathbb{R}_{i \rightarrow j}^{\text{all}} - 6(\tilde{\Omega} + 1)}{\tilde{\Omega}(\tilde{\Omega} - 1)}$
RF_k	(Kolisch i in., 1995)	$\frac{1}{\tilde{\Omega}} \sum_{i=1}^{\tilde{\Omega}} \frac{1}{\tilde{\mathcal{M}}_i^{\omega}} \sum_{m=1}^{\tilde{\mathcal{M}}_i^{\omega}} \begin{cases} 1 & \omega[i, m, \rho_k] > 0 \\ 0 & \omega[i, m, \rho_k] = 0 \end{cases}$
RS_k	(Cooper, 1976)	$\frac{\bar{\rho}_k}{\frac{1}{\tilde{\Omega}} \sum_{i=1}^{\tilde{\Omega}} \omega[i, 1, \rho_k]}$
RS_k	(Kolisch i in., 1992) ^{ab}	$\frac{\bar{\rho}_k - r_k^{\min}}{r_k^{\max} - r_k^{\min}}$
RS_k	(Demeulemeester i in., 2003) ^{ac}	$\frac{\bar{\rho}_k - r_k^{\min}}{r_k^{\max} - r_k^{\min}}$
RU_i	(Demeulemeester i in., 2003)	$\sum_{k=1}^{\tilde{\Psi}_R} \begin{cases} 1 & \omega[i, 0, \rho_k] > 0 \\ 0 & \omega[i, 0, \rho_k] = 0 \end{cases}$
RC_k^d	(Patterson, 1976)	$\frac{\sum_{i=1}^{\tilde{\Omega}} \omega[i, m, \rho_k]}{a_k \sum_{i=1}^{\tilde{\Omega}} v(i, k)}$
TRC^e	(Thesen, 1976)	$\frac{\sum_{i=1}^{\tilde{\Omega}} \sum_{r=1}^{\tilde{\Psi}_R} \omega[i, m, \rho_r] * \omega[i, m, \mathcal{T}]}{\tilde{\Omega} * T_{CPM}}$

^a $r_k^{\max}$ równa się maksymalnej wielkości zapotrzebowania na k -ty zasób obliczonej dla harmonogramu bez ograniczeń zasobowych

$$b_r^{\min} = \max_{i=1, \dots, \tilde{\Omega}} \left\{ \min_{m=1, \dots, \tilde{\mathcal{M}}_i^{\omega}} \omega[i, m, \rho_k] \right\}$$

$$c_r^{\min} = \max_{i=1, \dots, \tilde{\Omega}} \left\{ \max_{m=1, \dots, \tilde{\mathcal{M}}_i^{\omega}} \omega[i, m, \rho_k] \right\}$$

^d(ang. *Resource Constrainedness*)

^e(ang. *Tightness of Resource Constraints*)

Tab. 6.1: Mierniki oceny struktury sieci oraz ścisłości ograniczeń zasobowych.

- badania przeprowadzono w grupie problemów o różnej: liczbie czynności, strukturze i stopniu ściśłości ograniczeń zasobowych,
- z uwagi na stochastyczny charakter procedur badania przeprowadzono każdorazowo na grupie 10 problemów dla każdego zestawu parametrów modelu.

W badaniach do przekształcenia odnalezionego uszeregowania czynności w harmonogram zastosowano procedurę, którą zaproponowali (Ulusoy i in., 2001) przedstawioną na alg. 5.3 zgodnie z argumentacją przedstawioną w p. 5.2.

Badania podzielono na następujące etapy:

- Badanie wpływu parametrów poszczególnych metaheurystyk na ich skuteczność w optymalizacji harmonogramów projektów na grupie problemów o liczbie czynności $\tilde{Q} = 30$.
- Badanie wpływu rozmiaru i parametrów problemu na skuteczność metaheurystyk z najlepszym zestawem parametrów (zgodnie z pierwszym etapem badań). Badania te realizowano na grupie problemów o liczbie czynności $\tilde{Q} \in \{30; 60; 90\}$.
- Badanie skuteczności bezwzględnej analizowanych metaheurystyk oparte na analizie porównawczej z rozwiązaniami optymalnymi dla problemów o liczbie czynności $\tilde{Q} = 10$.
- Analiza korelacji kryteriów optymalizacji czasowej i NPV dla problemów o liczbie czynności $\tilde{Q} = 10$.

Dla zapewnienia jednolitych warunków i porównywalności wyników pomiędzy poszczególnymi rodzajami badanych metaheurystyk we wszystkich przypadkach zastosowano ograniczenie maksymalnej liczby generowanych harmonogramów do $\tilde{A} = 20\ 000$.

6.1.4 Środowisko obliczeniowe

Środowisko obliczeniowe zbudowane dla realizacji eksperymentów składa się z następujących elementów:

- programu PSch opracowanego dla potrzeb realizacji niniejszej pracy w środowisku programowania Borland Delphi 5.0 (z wykorzystaniem pakietu FlexCel w wersji 2.5.3). Program obejmuje swoją funkcjonalnością: generowanie problemów klasy RCPS w formacie pso (opisanym w zał. B) zgodnie z modelem opisanym w p. 4.1, analizę parametrów modeli klasy RCPS, moduł budowy harmonogramu w oparciu o statyczne priorytety zadań zgodnie z alg. 5.2, moduł oceny jakości harmonogramu według wybranych kryteriów zgodnie z opisem w p. 4.2 oraz modułów pomocniczych do prezentacji, edycji i konwersji danych,
- arkusza kalkulacyjnego służącego jako interfejs do prezentacji wyników obliczeniowych poszczególnych eksperymentów – wyniki każdego z eksperymentów zapisywane są w formacie BIFF8,
- aplikacji gromadzącej i przygotowującej wyniki obliczeń do analizy statystycznej opartej o bazę danych Microsoft Access,
- programów Statistica firmy StatSoft i SPSS firmy SPSS, wykorzystywanych do analizy statystycznej wyników przeprowadzonych eksperymentów obliczeniowych i prezentacji wyników.

Zestawy parametrów oraz statystyki wyników przeprowadzanych eksperymentów zapisywane są do pliku w formacie BIFF8, który zawiera w formie tabelarycznej i graficznej informacje o trajektorii poszukiwań. Zapis każdego eksperymentu stanowi oddzielny plik. W zależności od rodzaju badanej metaheurystyki rejestrowane są stany poszczególnych zmiennych oraz wybrane wielkości opisujące przeszukiwane fragmenty przestrzeni rozwiązań. Z uwagi na znaczną skalę prowadzonych badań zrezygnowano z rejestrowania poszczególnych generowanych harmonogramów. Analizą generowanych harmonogramów posługiwano się

w początkowej fazie badań dla przeprowadzenia weryfikacji poprawności działania oprogramowanych procedur budowy oraz oceny jakości harmonogramu. Na etapie oceny skuteczności wybranych metaheurystyk nie ma potrzeby przeprowadzania tego rodzaju analizy. W każdym przypadku rejestrowano zarówno dopuszczalne jak i niedopuszczalne rozwiązania wygenerowane w procesie poszukiwań, zapisując uzyskaną wartość funkcji celu (λ). W przypadku procedur opartych na populacji osobników rejestrowano uzyskaną w populacji jednorodność mierzoną w sposób, który proponuje Hartmann (2001) zarówno w zakresie kolejności szeregowania czynności (ang. *similarity of the activity lists*) jak i sposobów wykonania tychże czynności (ang. *similarity of the mode assignments*). Dla procedur operujących na jednym rozwiązaniu rejestrowano wybrane punkty na trajektorii poszukiwań. Rejestracja bardziej szczegółowych danych znacznie spowalnia realizację eksperymentów i nie wnosi żadnej dodatkowej wartości dla późniejszej analizy uzyskanych wyników.

6.1.5 Metodyka analizy i oceny wyników badań

Uzyskane w eksperymentach wyniki poddane zostały analizie statystycznej dla ustalenia istotności pomierzonych efektów. Jako miarę służącą do oceny skuteczności działania poszczególnych procedur przyjęto względne odchylenie/błąd rozwiązania (λ_{MH}) wybranego problemu odnalezonego przez wybraną procedurę (MH) od najlepszego znanego (odnalezonego lub dokładnego) rozwiązania tegoż problemu w postaci:

$$\epsilon = \frac{\max \{\lambda\} - \lambda_{MH}}{\max \{\lambda\}} \quad (6.3)$$

W przypadku analizy wpływu parametrów zarówno modelu jak i metaheurystyki na skuteczność procesu poszukiwania posłużono się średnim odchyleniem $\bar{\epsilon}$ dla określonej grupy problemów.

Dodatkowo dla określenia istotności zaobserwowanych zjawisk wykorzystano analizę ANOVA oraz testy *post-hoc*. Dla określenia zgodności rozkładów zmiennych w ramach przeprowadzonych eksperymentów wykorzystano test Shapiro-Wilka (SW) według opisu, który przedstawia Royston (1982) z modyfikacją dla prób większych niż 50 oraz test Kolmogorova-Smirnoffa (KS) wraz z modyfikacją, którą proponuje Lilliefors (1967). Dodatkowo w przypadku wątpliwości dokonywano analizy histogramów analizowanych zmiennych. Dla sprawdzenia założenia o jednorodności wariancji w badanych zabiegach stosowano test Levene'a zgodnie z opisem w (Wilcox, 2002). W przypadku spełnienia założenia o jednorodności wariancji dla weryfikacji hipotezy o równości średnich w próbie wykorzystano test F z ANOVA (oznaczone jako test ANOVA). W przypadku niespełnienia założenia o jednorodności wariancji dla weryfikacji hipotezy o równości średnich stosowano odporne testy: Browna-Forsythe'a (Brown i Forsythe, 1974) oraz Welch'a (Welch, 1951). W przypadku odrzucenia hipotezy o równości średnich w grupach dla oceny istotności stwierdzonych różnic wykorzystano testy *post-hoc*. Dla danych spełniających założenia o jednorodności wariancji stosowano najpopularniejszy i szeroko stosowany, konserwatywny test Tukey'a HSD (ang. *Honestly Significant Difference*), który opisują m.in. Hsiung i Olejnik (1994), Klockars i McAweeney (1995), Kromerey i Rocca (1995), Wilcox (2002). W przypadku nierównej liczby pomiarów w komórkach stosowano HSD z modyfikacją, którą zaproponował Kramer (1956). W przypadku braku spełnienia założenia o jednorodności wariancji stosowano jako metodę liberalną zmodyfikowaną wersję testu HSD, którą zaproponowali Games i Howell (1976) (GH) oraz jako metodę konserwatywną test Tamhane (T2) opisany w (Hochberg i Tamhane, 1987, Wilcox, 2002). W wybranych przypadkach istotnych różnic pomiędzy zaobserwowanymi rozkładami zmiennej losowej, a rozkładem normalnym stosowano metody rangowe: test mediany i odpowiednik jednoczynnikowej ANOVA, czyli test Kruskala-Wallisa (KW) oraz wielokrotne porównania średnich rang (Kruskal i Wallis, 1952) dla zbadania istotnych różnic pomiędzy efektami. Dla analizy wybranych zjawisk w parametrach ilościowych (m.in. wpływ p_β , p_α na $\bar{\epsilon}$) wnioskowano na podstawie współczynnika korelacji Pearsona i wyników analizy regresji liniowej.

Przy określaniu siły związku pomiędzy zmiennymi zależnymi i niezależnymi w wieloczynnikowej ANOVA posługiwano się wskaźnikiem eta-kwadrat (η^2) dla określenia względnego (dla danego porównania) udziału efektu w objaśnieniu zmienności oraz częściową eta-kwadrat (η_p^2) dla bezwzględnego porównania siły

związku pomiędzy różnymi ANOVA zgodnie z opisem i uwagami, które przedstawiają Kirk (2007), Levine i Hullett (2002), Olejnik i Algina (2000).

W całości badań przeprowadzano wnioskowanie przy $\alpha = 0,05$ poziomie ufności.

6.2 Analiza wpływu parametrów na efektywność wybranych metaheurystyk

Poniżej zestawiono analizę wyników eksperymentów dla zestawu 270 modeli o liczbie czynności $\tilde{Q} = 30$. Kolejno przedstawiono wyniki dla wybranych do badania metaheurystyk: SA, GA, TS, HA. Pełne zestawienie statystyk opisowych dla przeprowadzonych eksperymentów wraz z wartościami parametrów metaheurystyk oraz modeli przedstawiono w zał. C (s. 119).

6.2.1 Analiza wpływu parametrów na efektywność algorytmu SA

W badaniach zastosowano algorytm SA wraz z ogólną modyfikacją, którą zaproponowali Bouleimen i Lecocq zgodnie z opisem w p. 5.4. Wyniki badań, które prezentują w pracy (Bouleimen i Lecocq, 2003) wskazują na zdecydowaną wyższość zaproponowanego procesu poszukiwania nad ogólną procedurą SA dla modeli z kryterium oceny opartym na czasie zakończenia realizacji zbioru czynności. Procedura SA posiada dwa rodzaje parametrów:

- jakościowe – do których można zaliczyć: rodzaj operatora zastosowanego w modyfikacji sposobu wykonania czynności, rodzaj operatora zastosowanego w modyfikacji kolejności czynności β ,
- ilościowe – do których można zaliczyć: prawdopodobieństwo zastosowania operatora w zakresie zmiany kolejności czynności w uszeregowaniu p_p , intensywność stosowania operatora w zakresie zmiany sposobów wykonania czynności p_m , liczbę reinicjalizacji (łańcuchów) poszukiwań C , liczbę kroków S , inicjalizacyjny rozmiar przeszukiwanego otoczenia N , parametr h modyfikujący długość kroku algorytmu, parametr $\Delta_{\max}$ ograniczający wartość T_0 .

Modyfikację sposobu wykonania czynności przeprowadzano dla wszystkich badań SA, jako losowy wybór sposobu wykonania ze zbioru sposobów wykonania dla i -tej czynności (M_i^w). Rodzaj operatora kolejnościowego może przyjmować trzy wartości: HM (mutacja Hartmanna) zgodnie z alg. 5.5 lub BM (mutacja Boctora) zgodnie z alg. 5.4 oraz MM (mutacja polegająca na losowym wyborze jednego z dwóch poprzednich operatorów z równym prawdopodobieństwem). Parametry p_m oraz p_p mogą przyjmować wartości z zakresu $[0; 1]$, gdzie 0 oznacza brak zastosowania operatora, natomiast 1 oznacza zastosowanie operatora każdorazowo przy generowaniu sąsiada. Parametr liczby reinicjalizacji C może przyjmować teoretycznie dowolną wartość naturalną większą od 0, jednak w praktyce zakres jego zmienności jest ograniczony przez liczbą generowanych rozwiązań oraz długość procesu poszukiwania w ramach każdego z łańcuchów. Parametr h może przyjmować dowolną wartość naturalną, jednak od jego wielkości zależeć będzie intensywność poszukiwań wyrażająca się w wielkości sąsiedztwa, a co za tym idzie długości każdego kroku. Wraz ze wzrostem h długość każdego kroku zwiększa się, co pozwala na bardziej intensywne przeszukiwanie fragmentu przestrzeni parametrów jednocześnie ograniczając eksplorację z uwagi na ograniczoną całkowitą liczbę ewaluacji parametrów rozwiązania. Parametry: liczba kroków S oraz początkowy rozmiar otoczenia N są dowolnymi liczbami naturalnymi większymi od zera. Jednak w przypadku ograniczenia liczby generowanych rozwiązań istotny jest ich właściwy dobór tak, aby w ramach każdego łańcucha możliwe było przeprowadzenie pełnego cyklu poszukiwania. Brak uwzględnienia tego warunku spowoduje zapisanie wyniku poszukiwań przerwanych w losowym momencie. Pełne zestawienie wszystkich przebadanych kombinacji parametrów (uszeregowane według malejącego $\bar{e}$) wraz z podstawowymi statystykami opisującymi uzyskane wyniki znajduje się w tab. C.1 (s. 120).

Analiza wpływu sposobu generowania sąsiedztwa na efektywność SA

W ramach badanych rodzajów operatorów kolejnościowych (technik generowania sąsiedztwa) dla potrzeb algorytmu SA wykorzystano opisane w p. 5.3.2 procedury mutacji: Hartmanna, Boctora lub mieszaną. W

c	s	N_s	N_{tot}
1	1	33	33
1	2	39	72
1	3	50	122
1	4	70	192
1	5	105	297
1	6	168	465
1	7	285	750
1	8	513	1 263
1	9	974	2 237
1	10	1 948	4 185
2	1, ..., 10	4 185	8 370
3	1, ..., 10	4 185	12 555
4	1, ..., 10	4 185	16 740
5	1, ..., 9	2 237	18 977
5	10	1 023	20 000

Tab. 6.2: Wielkości sąsiedztw w procesie poszukiwania dla $C = 5$, $S = 10$, $N = 30$ oraz $h = 0$

badaniach zezwolono na pięciokrotne uruchomienie algorytmu ($C = 5$) dobierając pozostałe parametry tak, aby całkowita liczba wygenerowanych przez procedurę rozwiązań $\tilde{N} = 20\,000$. Parametr N przyjęto na poziomie 30, natomiast S na poziomie 10 co pozwala wykonać pełne $C = 5$ reinicjalizacji. Ostatni badany osobnik jest 1023-cim punktem poszukiwań dla 10-tego kroku w 5-tym łańcuchu. W przypadku zmniejszenia wartości N do 29 proces poszukiwania zakończyłby się przed wygenerowaniem 20 000 rozwiązań. W tab. 6.2 przedstawiono liczbę osobników badanych w każdym kroku przy założonych powyżej parametrach. Wyraźnie widać założony wzrost intensywności poszukiwań w kolejnych krokach algorytmu, co związane jest koniecznością coraz głębszej eksploatacji otoczenia dla odnalezienia rozwiązania lepszego od bieżącego. Przeszukiwanie sąsiedztwa odbywa się poprzez zastosowanie przeszukiwania przeszukiwania w zakresie kolejności czynności z prawdopodobieństwem $p_p \in \{0,10; 0,30; 0,50; 0,70; 0,90\}$. W obszarze sposobów wykonania czynności rozpoczęto badanie od $p_m \in \{0,10; 0,30; 0,50; 0,70; 0,90\}$, jednak z uwagi na uzyskane wyniki rozszerzono badanie na wartości $p_m \in \{0,01; 0,02; 0,04; 0,06; 0,08\}$. Możliwie szeroki wybór kombinacji parametrów p_p i p_m pozwoli określić efektywność operatora kolejnościowego niezależnie od intensywności jego wykorzystania. Badania prowadzono przy $h = 0$ i $\Delta_{\max} = 0,2$.

W pierwszej kolejności przeanalizowano wpływ p_m i p_p na efektywność poszukiwań dla **HM** i **BM**. Wstępna analiza uzyskanych wyników wskazała na możliwość korelacji pomiędzy p_m i $\bar{\epsilon}$ dla weryfikacji tej hipotezy przeprowadzono analizę regresji liniowej. Wyniki analizy regresji dla zmiennej objaśniającej $p_m \geq 0,1$ dla **HM** i **BM** oraz wybranych poziomów p_p :

- przy $\beta = \text{HM}$ i $p_p = 0,90$:

$$R = 0,812; R^2 = 0,659; F(1; 1348) = 2610,43; p < 0,001;$$

$$\bar{\epsilon} = 1,914_{t=6,42}^{\pm 0,298} + p_m * 26,527_{t=51,09}^{\pm 0,519}$$

- przy $\beta = \text{BM}$ i $p_p = 0,90$:


$$R = 0,832; R^2 = 0,691; F(1; 1348) = 3021,44; p < 0,001;$$

$$\bar{\epsilon} = -1,676_{t=-5,33}^{\pm 0,314} + p_m * 30,053_{t=54,97}^{\pm 0,547}$$

- przy $\beta = \text{HM}$ i $p_p = 0,70$:

$$R = 0,804; R^2 = 0,647; F(1; 1348) = 2465,78; p < 0,001;$$

$$\bar{\epsilon} = 2,41_{t=7,90}^{\pm 0,305} + p_m * 26,376_{t=49,66}^{\pm 0,531}$$



Rys. 6.2: Wpływ p_m na $\bar{\epsilon}$ w zależności od p_p dla SA z (a) $\beta = \text{BM}$ i (b) $\beta = \text{HM}$ ($C = 5$; $S = 10$; $N = 30$; $h = 0$; $\Delta_{\max} = 0,2$).

- przy $\beta = \text{BM}$ i $p_p = 0,70$:


$$R = 0,826; R^2 = 0,682; F(1; 1348) = 2887,21; p < 0,001;$$

$$\bar{\epsilon} = -0,853_{t=-2,76}^{\pm 0,309} + p_m * 28,933_{t=53,73}^{\pm 0,538}$$

Przeprowadzona analiza wskazuje na związek pomiędzy p_m i $\bar{\epsilon}$ zarówno dla BM, jak i HM. Wyniki potwierdzają istnienie silnej dodatniej korelacji pomiędzy p_m , a uzyskanym $\bar{\epsilon}$ ($R > 0,8$). Wszystkie estymatory regresyjne parametrów wykazują istotność przy $\alpha = 0,05$ (wartości t podano w indeksie dolnym przy estymatorach, w indeksie górnym zaznaczono oszacowanie błędu s_E). W przypadku $p_p = 0,90$ wzrost p_m o 0,1 (w zakresie od 0,1 do 1,0) powoduje wzrost $\bar{\epsilon}$ o 2,65% w przypadku HM, natomiast dla BM powoduje wzrost $\bar{\epsilon}$ o 3,0%. Dla $p_p = 0,7$ zmniejsza się kąt nachylenia prostej dla każdego z operatorów.

Z uwagi na uzyskany wynik zdecydowano się przeanalizować szczegółowo wyniki SA dla $p_m < 0,1$. Podsumowanie uzyskanych wyników $\bar{\epsilon}$ w formie graficznej dla całego zakresu analizy p_m przedstawiono na rys. 6.2 zarówno dla $\beta = \text{BM}$, jak i $\beta = \text{HM}$. W tab. D.24 (s. 173) przedstawiono wyniki testów istotności statystycznej różnicy wyników dla $p_m < 0,1$ oraz w tab. D.26 (s. 174) dla $p_m \geq 0,1$. Wyniki analizy wariancji zestawiono odpowiednio w tab. D.23 (s. 173) oraz tab. D.25 (s. 174). Podział na dwie grupy wynika ze znacznego wzrostu $\bar{\epsilon}$ dla $p_m > 0,1$, który uniemożliwia stwierdzenie różnic pomiędzy relatywnie zbliżonymi wynikami dla $p_m < 0,1$. Wyniki dla $p_m < 0,1$ przeanalizowano za pomocą ANOVA i testów *post-hoc* z uwagi na zauważalną zmianę nachylenia krzywej regresji dla wszystkich badanych wartości p_p w tym zakresie p_m . Jednocześnie dołączenie tych wyników do przedstawionej uprzednio analizy regresji, nie wpłynie znacząco na jej wyniki, co nie pozwoli na stwierdzenie granicznej minimalnej wartości p_m – wartość 0 powoduje znaczny wzrost błędu z uwagi na znaczne ograniczenie przeszukiwania w ramach sposobów wykonania czynności. Analiza wyników testów T2 i GH (tab. D.26) dla $p_m < 0,1$ wskazuje na brak istotnych różnic pomiędzy $\bar{\epsilon}$ w przypadku $p_m \in \{0,01; 0,02; 0,04\}$ dla BM (w porównaniu #10 dla $p_p = 0,90$ dodatkowo w grupie jednorodnej znajduje się $p_m = 0,06$).

Parametr p_p odpowiada za sterowanie intensywnością wykorzystania operatora β w procesie poszukiwania, czyli za intensywność przeszukiwania uszeregowanych czynności. W tab. D.28 (s. 175) przedstawiono wyniki testów istotności uzyskanych $\bar{\epsilon}$ w zależności od p_p . We wszystkich analizowanych przypadkach ($p_m \in \{0,02; 0,10; 0,30; 0,50\}$) z operatorem BM nieistotne są różnice w wynikach uzyskanych dla $p_p \geq 0,5$. Natomiast dla HM jedynie w przypadku $p_m = 0,50$ różnice wyniku są nieistotne dla $p_p \geq 0,30$. Jednak porównanie to z uwagi na wysoki poziom p_m charakteryzuje się wysokim błędem na poziomie od 15,99% dla $p_p = 0,90$ do 17,60% dla $p_p = 0,10$. Najbardziej interesujące są porównania dla $p_m = 0,02$ z uwagi




Rys. 6.3: Wpływ β na $\bar{\epsilon}$ w zależności od C dla $\mathcal{SA}$ ($S = 5$; $p_p = 0,90$; $p_m = 0,02$; $h = 0$; $\Delta_{\max} = 0,2$).

na najniższy poziom $\bar{\epsilon}$. Zarówno dla HM (porównanie #1 w tab. D.28), jak i dla BM (porównanie #5 w tab. D.28) nie ma statystycznie istotnej różnicy pomiędzy $p_p \in \{0,90; 0,70; 0,50\}$.

Na rys. 6.3 przedstawiono wpływ β na $\bar{\epsilon}$ dla $C = 1, \dots, 10$ przy $S = 5$, $p_p = 0,90$, $p_m = 0,02$, $h = 0$, $\Delta_{\max} = 0,2$. W tab. D.17 (s. 170) zestawiono średnie wyniki uzyskane przez $\mathcal{SA}$ w zależności od wykorzystanego rodzaju operatora (HM , BM lub MM). W tab. D.16 (s. 170) zestawiono wyniki ANOVA dla powyższych porównań. Porównanie $\bar{\epsilon}$ wskazuje na niższą od BM efektywność stosowania dla HM lub MM niezależnie od poziomu intensywności wykorzystania operatora. We wszystkich analizowanych przypadkach $\bar{\epsilon}$ dla BM jest istotnie różne od HM i MM . Różnice pomiędzy $\bar{\epsilon}$ dla HM i MM są statystycznie nieistotne we wszystkich porównaniach. Wydaje się, że wynika to wprost z konstrukcji operatora HM , który w odróżnieniu od BM pozwala na uzyskiwanie bardzo bliskich sąsiadów poprzez zamianę pozycji dwóch kolejnych czynności w uszeregowaniu (por. alg. 5.4 i alg. 5.5). Ponadto w przypadku zastosowania go w procedurze $\mathcal{SA}$, która nie posiada dodatkowych mechanizmów pozwalających opuszczać lokalne minima, co może powodować stagnację algorytmu. Procedura BM z uwagi na wymianę dwóch losowo wybranych czynności z dowolnych miejsc spełniających ograniczenia kolejnościowe pozwala na wygenerowanie relatywnie odleglejszego sąsiada z przestrzeni parametrów, jednocześnie pozwalając również uzyskać sąsiada *bliskiego* jak w przypadku HM . Obiecującym rozwiązaniem w świetle powyższych wyników wydaje się zastosowanie BM na początkowym etapie realizacji kolejnego kroku, natomiast wykorzystanie HM dla głębszej eksploatacji wybranego fragmentu pod koniec poszukiwań. Możliwe jest też opracowanie nowego operatora parametrycznego na bazie BM , którego zróżnicowanie generowanych sąsiadów (mierzony np. za pomocą odległości Hartmanna) będzie sterowane adaptacyjnie.

Analiza wpływu strategii poszukiwania (C , S i N) na efektywność $\mathcal{SA}$

Sposób w jaki $\mathcal{SA}$ przeszukuje przestrzeń parametrów sterowany jest poprzez parametry: C , S oraz N , które decydują o poziomie eksploracji (poprzez rozpoczynanie poszukiwań z losowo wybranego punktu) i eksploatacji (poprzez przeszukiwanie fragmentu przestrzeni parametrów w ramach kolejnego kroku). Z uwagi na wprowadzone ograniczenie całkowitej liczby generowanych rozwiązań strategią poszukiwania można sterować za pomocą wartości dowolnych dwóch parametrów, gdyż wartość trzeciego z nich będzie zdeterminowana możliwością realizacji pełnego cyklu poszukiwań. Na rys. 6.3 (s. 81) przedstawiono $\bar{\epsilon}$ dla wartości $C = 1, \dots, 10$ przy stałych parametrach $S = 5$, $p_p = 0,90$, $p_m = 0,02$, $h = 0$, $\Delta_{\max} = 0,2$. W przypadku stosowania HM lub MM , $\mathcal{SA}$ wykazuje najlepszy efekt przy $C = 2$. Zwiększanie wartości parametru C powoduje wzrost $\bar{\epsilon}$ od wartości 1,22% dla HM i 1,21% dla MM do 1,60% i 1,71% odpowiednio dla $C = 10$. Wzrost $\bar{\epsilon}$ wynika ze skracania trajektorii poszukiwań w ramach kolejnych 5




Rys. 6.4: Wpływ S na $\bar{\epsilon}$ w zależności od C dla $\mathbb{SA}$ ($\beta = \mathbb{BM}$; $p_p = 0,90$; $p_m = 0,02$; $h = 0$; $\Delta_{\max} = 0,2$).

kroków, z $N = 989$ dla $C = 2$ do $N = 199$ dla $C = 10$. Wynika to z faktu, że zastosowanie słabszych (w porównaniu do $\mathbb{BM}$) operatorów β wymaga dłuższego procesu poszukiwania dla uzyskania podobnych wyników. Spadek $\bar{\epsilon}$ przy $C = 1$ wskazuje, że powtarzanie poszukiwań (od nowego losowo wygenerowanego punktu) zwiększa znacznie szanse na lepszą eksplorację przestrzeni poszukiwań – w $\mathbb{SA}$ brak jest innego mechanizmu wspomagającego eksplorację, więc zwiększanie liczby powtórzeń daje znaczną poprawę, o ile w ramach każdego C , liczba S i N pozwoli na wystarczającą eksploatację fragmentu przestrzeni rozwiązań. Szczególnie wyraźnie widać to przy zastosowaniu $\mathbb{BM}$, który z uwagi na sposób generowania sąsiedztwa jest bardziej skłonny do eksploracji i tym samym bardziej odporny na zmiany C . W tym przypadku zmiana wartości C w zakresie od 2 do 8 nie powoduje istotnego statystycznie wzrostu wartości $\bar{\epsilon}$ (do 0,50%). Jedynie w przypadku braku powtarzania poszukiwań i $C > 8$ uzyskane $\bar{\epsilon}$ jest istotnie różne od wyniku $\bar{\epsilon} = 0,42\%$ dla $C = 5$. (tab. D.19). Przy zmianie wartości S zmniejsza się odporność $\mathbb{SA}$ na zmiany C . W przypadku zmniejszenia S do poziomu 3, najlepsze $\bar{\epsilon} = 1,18\%$ uzyskano dla $C = 2$. Zmiana wartości C powyżej 6, powoduje istotne statystycznie pogorszenie (zwiększenie) uzyskanego $\bar{\epsilon}$. W przypadku zwiększenia liczby kroków do $S = 10$ ciężar poszukiwań jest całkowicie przeniesiony na eksplorację, gdyż wartość N spada do 141 dla $C = 1$ i jedynie 14 dla $C = 10$. Przy tak krótkich łańcuchach, konieczne jest zwiększenie ich liczby dla uzyskania satysfakcjonującego $\bar{\epsilon}$. Najlepsze wyniki uzyskano dla $C = 9$ ($\bar{\epsilon} = 0,68\%$). Zmniejszenie wartości C do 4 nie powoduje istotnej statystycznie zmiany $\bar{\epsilon}$ (do 0,87%). Najlepszy uzyskany wynik dla $S = 10$ przy $C = 9$ jest istotnie gorszy statystycznie od wyniku dla $S = 5$ i $C = 5$ ($F(1; 538) = 31,59$; $p < 0,001$).

W tab. D.21 (s. 172) przedstawiono wyniki analizy wariancji dla $S \in \{3; 5; 10\}$ przy $C \in \{1; 2; 3; 4; 5; 6; 7; 8; 9; 10\}$ oraz $\beta = \mathbb{BM}$, $p_p = 0,9$, $p_m = 0,02$, $\Delta_{\max} = 0,2$ i $h = 0$. W tab. D.22 (s. 172) zestawiono wyniki testów *post-hoc* dla zaplanowanych porównań. W każdym z porównań wyniki uzyskane dla $S = 5$ są istotnie lepsze od wyników dla $S = 3$ lub $S = 10$. Najlepszy wynik uzyskany dla $S = 5$ i $C = 5$ wynosi 0,42% przy $\bar{\epsilon} = 0,87\%$ dla $S = 10$ i $\bar{\epsilon} = 1,31\%$. Dla małej liczby łańcuchów ($C < 3$) lepsze wyniki uzyskano z $S = 3$ jednak wyniki te są statystycznie jednorodne, w pozostałych przypadkach wyniki dla $S = 10$ są istotnie lepsze od wyników dla $S = 3$.

Analiza wpływu $\Delta_{\max}$ na efektywność $\mathbb{SA}$

Na rys. 6.5 przedstawiono wpływ $\Delta_{\max}$ na $\bar{\epsilon}$ dla $\mathbb{SA}$ przy $C = 1, \dots, 10$, $S = 5$, $\beta = \mathbb{BM}$, $p_p = 0,90$, $p_m = 0,02$, $h = 0$. W przypadku $C \in \{1; 2; 3; 4; 6; 8; 9; 10\}$ nie stwierdzono statystycznie istotnych różnic pomiędzy wynikami $\mathbb{SA}$ przy różnych poziomach $\Delta_{\max}$ (odpowiednie wartości ANOVA znajdują się w tab. D.30). Dla $C = 5$ wyniki uzyskane przy $\Delta_{\max} = 0,1$ ($\bar{\epsilon} = 0,54\%$) są istotnie gorsze (wartość $p = 0,024$



Rys. 6.5: Wpływ $\Delta_{\max}$ na $\bar{\epsilon}$ w zależności od C dla $\mathbb{SA}$ ($S = 5$; $\beta = \mathbb{BM}$; $p_p = 0,90$; $p_m = 0,02$; $h = 0$)


dla testu T2 i $p = 0,022$ dla GH) od wyników uzyskanych przy $\Delta_{\max} = 0,2$ ($\bar{\epsilon} = 0,42\%$). W przypadku $C = 7$ wyniki uzyskane przy $\Delta_{\max} = 0,1$ ($\bar{\epsilon} = 0,55\%$) są istotnie gorsze (wartość $p = 0,014$ dla HSD, $p = 0,057$ w teście Levene'a i $p = 0,020$ w ANOVA) jedynie od wyników uzyskanych przy $\Delta_{\max} = 0,5$ ($\bar{\epsilon} = 0,43\%$). Nieznaczny wpływ wartości $\Delta_{\max}$ na $\bar{\epsilon}$ wynika z faktu, że parametr ten stanowi jedynie podstawę do wyliczenia T_0 , więc ma jedynie wpływ na tempo zbieżności $\mathbb{SA}$ w początkowej fazie. W większości (8 na 10) analizowanych przypadków najniższe wartości $\bar{\epsilon}$ uzyskano dla $\Delta_{\max} = 0,2$.

6.2.2 Analiza wpływu parametrów na efektywność algorytmu $\mathbb{GA}$

Badaniami objęto $\mathbb{GA}$ przedstawiony na alg. 5.13 zgodny z opisem w p. 5.6. Procedura $\mathbb{GA}$ w tej formie posiada dwa rodzaje parametrów:

- jakościowe – do których można zaliczyć: rodzaj operatora krzyżowania (α), rodzaj operatora mutacji (β), rodzaj operatora selekcji (ϕ), elityzm (E),
- ilościowe – do których można zaliczyć: prawdopodobieństwo zastosowania operatora krzyżowania (p_α), prawdopodobieństwo mutacji (p_β), wielkość populacji ($\mathcal{P}$), liczba pokoleń ($g_{\max}$).

W ramach badań zweryfikowano skuteczność operatorów mutacji stosowanych w zakresie kolejności uszeregowania zgodnie z opisem w p. 5.3.1. Mutację w sposobie wykonania czynności przeprowadzano jako losowy wybór sposobu wykonania ze zbioru sposobów wykonania dla i -tej czynności ($\mathcal{M}_i^\omega$), która podlegała mutacji w uszeregowaniu. Krzyżowanie realizowane jest za pomocą procedur opisanych w p. 5.3.2. Parametry p_β oraz p_α mogą przyjmować wartości z zakresu $[0; 1]$, gdzie 0 oznacza brak zastosowania operatora, natomiast 1 oznacza zastosowanie operatora każdorazowo. Wielkość populacji oraz liczba pokoleń może przyjmować dowolną wartość większą od 0. W badaniach wykorzystano operatory mutacji: $\mathbb{HM}$, $\mathbb{BM}$ oraz $\mathbb{MM}$, który losowo wybiera sposób przeprowadzenia mutacji spośród dwóch pierwszych z równym prawdopodobieństwem. Z operatorów krzyżowania wykorzystano: $\mathbb{1PX}$, $\mathbb{2PX}$, $\mathbb{UX}$, $\mathbb{PSX}$, $\mathbb{MIX}$. Operator $\mathbb{MIX}$ polega na losowym wyborze spośród czterech pierwszych z równym prawdopodobieństwem. Wartości p_β przyjęto na poziomie $\{0,02; 0,04; 0,06; 0,08; 0,10; 0,30; 0,50\}$, prawdopodobieństwo krzyżowania $p_\alpha \in \{0,10; 0,30; 0,50; 0,70; 0,90\}$. Przebadano $\mathbb{GA}$ ze stałym rozmiarem populacji na poziomie $\mathcal{P} \in \{50; 100; 200; 400\}$ oraz liczbą pokoleń pozwalającą na wygenerowanie 20 000 rozwiązań, czyli odpowiednio $g_{\max} \in \{400; 200; 100; 50\}$. Kolejno przedstawiono analizę wpływu wartości poszczególnych parametrów na skuteczność $\mathbb{GA}$. Pełne zestawienie wszystkich przebadanych kombinacji parametrów (uszeregowane według malejącego $\bar{\epsilon}$) wraz z podstawowymi statystykami opisującymi uzyskane wyniki znajduje się w tab. C.2 (s. 126).



Rys. 6.6: Wpływ $\tilde{P}$ na $\bar{\epsilon}$ dla GA bez elityzmu w zależności od α ($p_\alpha = 0,9$) oraz β ($p_\beta = 0,1$).

Analiza wpływu strategii poszukiwania ($\tilde{P}$, $g_{\max}$, E) na efektywność GA


Na rys. 6.6 przedstawiono wpływ $\tilde{P}$ i $g_{\max}$ na $\bar{\epsilon}$ dla GA bez elityzmu, natomiast na rys. 6.7 przedstawiono zależność dla GA z elityzmem. W tab. D.1 (s. 156) i tab. D.2 (s. 157) przedstawiono podsumowanie wyników ANOVA i testów *post-hoc* dla $\tilde{P}$ i $g_{\max}$. Wyniki wskazują w każdym przypadku (niezależnie od rodzaju operatorów i zastosowania elityzmu) na istotny statystycznie wpływ kombinacji wielkości populacji i liczby pokoleń na jakość uzyskiwanych rozwiązań. W GA bez elityzmu najlepsze rezultaty osiągnięto dla ($\tilde{P} = 200$; $g_{\max} = 100$) oraz ($\tilde{P} = 400$; $g_{\max} = 50$). Wyniki testów *post-hoc* wskazują na statystyczną jednorodność $\bar{\epsilon}$ dla tych kombinacji $\tilde{P}$ i $g_{\max}$ w większości (za wyjątkiem GA z operatorem krzyżowania PSX i mutacji HM lub BM). W przypadku GA bez elityzmu najlepsze wyniki uzyskano dla ($\tilde{P} = 200$; $g_{\max} = 100$) oraz ($\tilde{P} = 100$; $g_{\max} = 200$). W przypadku 12 na 15 porównań wyniki uzyskane dla tych operatorów są statystycznie równe. W 3 porównaniach (tab. D.2 #16, #21, #28) kombinacja ($\tilde{P} = 100$; $g_{\max} = 200$) uzyskała wyniki istotnie różniące się statystycznie od ($\tilde{P} = 200$; $g_{\max} = 100$). W przypadku #21 $p = 0,044$ dla testu T2 oraz $p = 0,038$ dla GH, natomiast w teście HSD brak jest istotnych statystycznie różnic. Najlepszy wynik $\bar{\epsilon} = 1,17\%$ uzyskany dla ($\tilde{P} = 100$; $g_{\max} = 200$) jest o 0,24% gorszy od najlepszego wyniku $\bar{\epsilon} = 0,93\%$ uzyskanego dla ($\tilde{P} = 200$; $g_{\max} = 100$).

Wyniki wskazują na ($\tilde{P} = 200$; $g_{\max} = 100$) jako najkorzystniejszą kombinację wielkości populacji i liczby pokoleń przy ograniczeniu $\tilde{N} = 20\,000$ z uwagi na niski poziom $\bar{\epsilon}$ niezależnie od zmian innych parametrów GA. W przypadku stosowania strategii elitarniej konieczne jest zwiększenie wielkości populacji, które jednocześnie przekłada się niekorzystnie na zdolność eksploatacji algorytmu z uwagi na zmniejszenie $g_{\max}$ i w efekcie na wzrost $\bar{\epsilon}$.


Wyniki analizy ANOVA wpływu elityzmu na skuteczność GA przedstawiono w tab. D.15 (s. 168). Przeanalizowano GA dla $\tilde{P} \in \{100; 200; 400\}$. W jednym przypadku (#16) stwierdzono brak istotnej różnicy pomiędzy wynikami GA z elityzmem i bez elityzmu ($F(1; 538) = 15,59$; $p = 0,070$) w teście ANOVA. We wszystkich pozostałych przypadkach stwierdzono istotny statystycznie spadek $\bar{\epsilon}$ po wprowadzeniu elityzmu w zakresie od 0,26% do 4,83%. Wyniki wskazują na poprawę wyników niezależnie od zmian pozostałych parametrów GA.

Analiza wpływu rodzaju operatora krzyżowania na efektywność GA


W badaniach wpływu operatora krzyżowania na efektywność GA porównano wyniki GA z $\alpha \in \{1PX; PSX; 2PX; UX; MIX\}$ przy $\tilde{P} \in \{50; 100; 200; 400\}$, $\beta \in \{HM; BM; MM\}$, $p_\alpha = 0,9$,



Rys. 6.7: Wpływ $\tilde{P}$ na $\bar{\epsilon}$ dla GA z elityzmem w zależności od α ($p_\alpha = 0,9$) oraz β ($p_\beta = 0,1$).



Rys. 6.8: Wpływ $\alpha(p_\alpha = 0,9)$ na $\bar{\epsilon}$ dla GA z elityzmem w zależności od $\tilde{P}$ i β ($p_\beta = 0,1$).



Rys. 6.9: Wpływ α ($p_\alpha = 0,9$) na $\bar{\epsilon}$ dla GA bez elityzmu w zależności od $\tilde{\mathcal{P}}$ i β ($p_\beta = 0,1$).


$p_\beta = 0,1$ i $\zeta = 2$. Badaniami objęto zarówno GA z elityzmem, jak i bez. Wyniki analizy wariancji przedstawiono w tab. D.3 (s. 158), natomiast zestawienie średnich i wyniki testów *post-hoc* zamieszczono w tab. D.4 (s. 159).

We wszystkich analizowanych porównaniach uzyskany wynik w postaci $\bar{\epsilon}$ jest zależny od rodzaju operatora krzyżowania. W przypadku GA bez elityzmu najlepsze wyniki uzyskano dla 2PX niezależnie od wartości pozostałych parametrów. Jedynie w przypadku $\tilde{\mathcal{P}} = 50$ i $\beta = HM$ wynik ($\bar{\epsilon} = 3,09\%$) jest statystycznie jednorodny z wynikami dla MIX ($\bar{\epsilon} = 3,32\%$) i PSX ($\bar{\epsilon} = 3,47\%$). W pozostałych przypadkach $\bar{\epsilon}$ uzyskany przez GA z 2PX jest statystycznie istotnie lepszy (zarówno według T2 jak i GH) od GA z innymi operatorami krzyżowania. W przypadku GA z elityzmem najlepsze wyniki, bądź statystycznie jednorodne z najlepszymi uzyskał również $\alpha = 2PX$ dla wszystkich porównań. W szczególności dla $\tilde{\mathcal{P}} = 200$ i $\tilde{\mathcal{P}} = 400$, uzyskane przez GA z 2PX wyniki są istotnie lepsze od wszystkich pozostałych operatorów α . We wszystkich przypadkach (zarówno dla GA z elityzmem, jak i bez) UX uzyskał wyniki statystycznie różne od najlepszych niezależnie od wartości innych parametrów. Pozostałe operatory uzyskały wyniki zależne od wykorzystanego operatora β oraz wielkości populacji.


Drugim elementem wpływającym na skuteczność eksploracji poprzez α jest intensywność jego stosowania, wyrażona jako p_α . W ramach badań przeanalizowano wpływ p_α dla elitarnego GA z $\tilde{\mathcal{P}} = 200$, $\alpha \in \{2PX; MIX\}$, $\beta \in \{HM; BM; MM\}$, $p_\beta \in \{0,02; 0,1\}$ i $\zeta = 2$. Wyniki analizy wariancji zestawiono w tab. D.11 (s. 165), natomiast średnie $\bar{\epsilon}$ i wyniki testów *post-hoc* w tab. D.12 (s. 165). Wyniki ANOVA wskazują na istotne statystycznie różnice pomiędzy rezultatami dla analizowanych poziomów p_α we wszystkich przypadkach. Najniższą wartość $\bar{\epsilon} = 0,83\%$ uzyskano dla $p_\alpha = 0,90$ przy $\beta = BM$ i $p_\beta = 0,02$ (#8). Przy tych samych parametrach dla $p_\alpha = 0,7$ uzyskano $\bar{\epsilon} = 0,97\%$ i wynik ten nie jest statystycznie istotnie różny od $p_\alpha = 0,9$. Wyniki dla pozostałych poziomów p_α są statystycznie istotnie gorsze od wyników dla $p_\alpha = 0,7$ i $0,9$. We wszystkich analizowanych porównaniach wyniki uzyskane dla $p_\alpha = 0,9$ pozwalały na osiągnięcie najniższej wartości $\bar{\epsilon}$, bądź wartości o różnicy statystycznie nieistotnej względem najlepszej wartości $\bar{\epsilon}$ w porównaniu.

Analiza wpływu rodzaju operatora mutacji na efektywność GA


W badaniach wpływu operatora mutacji na efektywność GA porównano wyniki GA z $\beta \in \{HM; BM; MM\}$ przy $\tilde{\mathcal{P}} \in \{50; 100; 200; 400\}$, $\alpha \in \{1PX; PSX; 2PX; UX; MIX\}$, $p_\alpha = 0,9$, $p_\beta = 0,1$ i $\zeta = 2$. Badaniami objęto zarówno GA z elityzmem, jak i bez. Wyniki analizy wariancji dla GA bez elityzmu przedstawiono w tab. D.5 (s. 160), natomiast zestawienie średnich i wyniki testów *post-hoc* zamieszczono w tab. D.6



Rys. 6.10: Wpływ β ($p_\beta = 0,1$) na $\bar{\epsilon}$ dla GA bez elityzmu w zależności od $\tilde{\mathcal{P}}$ i α ($p_\alpha = 0,9$).



Rys. 6.11: Wpływ β ($p_\beta = 0,1$) na $\bar{\epsilon}$ dla GA z elityzmem w zależności od $\tilde{\mathcal{P}}$ i α ($p_\alpha = 0,9$).





Rys. 6.12: Wpływ p_α i p_β na $\bar{\epsilon}$ dla GA z $\beta = \text{BM}$ ($\tilde{\mathcal{P}} = 200$; $g_{\max} = 100$)

(s. 161). Wyniki ANOVA dla GA z elityzmem przedstawiono w tab. D.7 (s. 162), natomiast wyniki testów *post-hoc* zestawiono w tab. D.8 (s. 163).



W przypadku GA bez elityzmu najlepsze wyniki uzyskano dla HM w 16 na 20 porównań. Istotnie gorsze wyniki uzyskano dla BM niezależnie od wielkości populacji i rodzaju krzyżowania. Odmienna sytuacja ma miejsce dla GA z elityzmem, gdzie najlepsze wyniki uzyskano dla BM lub MM za wyjątkiem GA z PSX, który najniższe $\bar{\epsilon}$ uzyskał w kombinacji z HM. Najlepszy wynik $\bar{\epsilon} = 0,93\%$ uzyskano dla MM przy $\tilde{\mathcal{P}} = 200$ i $\beta = 2\text{PX}$. Wynik ten jest statystycznie istotnie lepszy od rezultatu dla MM ($\bar{\epsilon} = 1,13\%$) i HM ($\bar{\epsilon} = 1,30\%$). W przypadku GA z elityzmem dla $\alpha = \text{MIX}$ i $\tilde{\mathcal{P}} > 100$ rodzaj operatora mutacji nie ma istotnego wpływu na $\bar{\epsilon}$ (#19 i #20). W żadnym z porównań dla GA elitarnego BM nie uzyskał wyniku $\bar{\epsilon}$ istotnie lepszego od dwóch pozostałych operatorów, co skłania ku stosowaniu operatora MM, który poza kombinacjami z UX i PSX (o relatywnie wysokim poziomie $\bar{\epsilon}$) pozwala na uzyskanie najlepszego, bądź statystycznie jednorodnego z najlepszym wynikiem $\bar{\epsilon}$. W przypadku GA bez elityzmu wybór operatora mutacji ma znaczenie dla uzyskanego poziomu $\bar{\epsilon}$ w każdym z analizowanych przypadków. Przy czym w każdym przypadku BM uzyskał najwyższy poziom $\bar{\epsilon}$ i w 17 na 20 zestawów parametrów wynik istotnie gorszy od HM i MM.

Na podstawie powyższych wyników zalecanym operatorem dla GA elitarnego jest MM (lub BM, który w większości przypadków uzyskał wyniki statystycznie jednorodne z MM). W przypadku braku strategii elitarniej zalecane jest korzystanie z HM, który charakteryzuje się niższą zmiennością, co przy braku odpowiednio silnego naporu selekcyjnego (poprzez elityzm, lub relatywnie duży rozmiar turnieju w porównaniu z wielkością populacji) pozwala na ukierunkowanie procesu poszukiwania.


Drugim elementem mającym wpływ na skuteczność operatora mutacji jest intensywność jego stosowania wyrażona jako p_β prawdopodobieństwo mutacji. W tab. D.13 (s. 166) przedstawiono wyniki ANOVA dla $p_\beta < 0,1$ i $\tilde{\mathcal{P}} \in \{50; 100; 200; 400\}$, $\alpha \in \{1\text{PX}; \text{PSX}; 2\text{PX}; \text{UX}; \text{MIX}\}$, $p_\alpha \in \{0,1; 0,3; 0,5; 0,7; 0,9\}$, $\beta \in \{\text{HM}; \text{BM}; \text{MM}\}$, $\zeta = 2$. W tab. D.14 (s. 167) przedstawiono wyniki testów *post-hoc* dla przeprowadzonych porównań. Na rys. 6.12 przedstawiono porównanie zależności pomiędzy p_β i $\bar{\epsilon}$ dla $\beta = \text{BM}$. Na rys. 6.13 przedstawiono porównanie dla $\beta = \text{HM}$, natomiast na rys. 6.14 dla $\beta = \text{MM}$. Na wszystkich wykresach wyraźnie widać wzrost $\bar{\epsilon}$ przy wartościach $p_\beta > 0,1$ niezależnie od pozostałych parametrów GA. Analizę istotności różnic ograniczono do $p_\beta \leq 0,1$. Na podstawie analizy wyników testów *post-hoc* można zauważyć, że operator HM uzyskuje lepsze wyniki przy wyższym poziomie p_β , w odróżnieniu od BM, który najlepszy wynik $\bar{\epsilon} = 0,78\%$ uzyskuje dla $p_\beta = 0,04$ (przy $\alpha = 2\text{PX}$, #15) i wynik ten jest statystycznie różny od wyniku dla $p_\beta = 0,08$ czy $p_\beta = 0,1$. Podobnie w przypadku operatora MM najlepsze wyniki $\bar{\epsilon} = 0,84$ uzyskano dla $p_\beta = 0,04$, jednak w odróżnieniu od BM wyniki uzyskane dla pozostałych wartości p_β nie są statystycznie różne od wyniku dla $p_\beta = 0,04$. Pozwala to potwierdzić



Rys. 6.13: Wpływ p_α i p_β na $\bar{\epsilon}$ dla GA z $\beta = HM$ ($\tilde{\mathcal{P}} = 200$; $g_{\max} = 100$)



Rys. 6.14: Wpływ p_α i p_β na $\bar{\epsilon}$ dla GA z $\beta = MM$ ($\tilde{\mathcal{P}} = 200$; $g_{\max} = 100$)



Rys. 6.15: Wpływ ζ na $\bar{\epsilon}$ dla GA z $\alpha = \text{MIX}$ ($p_\alpha = 0,9$) i $\beta = \text{MM}$ ($p_\beta = 0,1$).

większą stabilność działania MM, wyrażoną mniejszą wrażliwością na p_β od BM. Niezależnie od wielkości populacji, rodzaju i intensywności operatora krzyżowania najlepszy lub statystycznie jednorodny z najlepszym wynikiem uzyskano w przypadku BM i MM dla $p_\beta = 0,04$. W przypadku HM stwierdzono większą stabilność wyników w zależności od p_β , jednak obciążoną znacznie wyższym poziomem błędów (najlepszy odnaleziony $\bar{\epsilon} = 1,29\%$).


Analiza wpływu strategii selekcji na efektywność GA

W ramach badań przeanalizowano wpływ wielkości turnieju w ramach procedury selekcji turniejowej. Przyjęto trzy poziomy $\zeta \in \{2; 3; 4\}$. Badania przeprowadzono dla GA z elityzmem i bez elityzmu przy $\tilde{\mathcal{P}} \in \{50; 100; 200\}$ i $\alpha = \text{MIX}$, $p_\alpha = 0,9$, $\beta = \text{MM}$, $p_\beta = 0,1$. Ogółem przeprowadzono 6 porównań, których wyniki ANOVA zestawiono w tab. D.9 (s. 164), natomiast podsumowanie wyników testów *post-hoc* zestawiono w tab. D.10 (s. 164). W 4 na 6 porównań najlepsze wyniki uzyskano dla $\zeta = 4$. W jednym przypadku (GA z elityzmem, $\tilde{\mathcal{P}} = 50$) najlepszy wynik $\bar{\epsilon} = 2,01\%$ uzyskano dla $\zeta = 2$, jednak pozostałe wyniki w tym porównaniu (#4) nie różnią się (w teście Welch'a: $F_W(2; 533) = 2,21$; $p = 0,111$). Natomiast dla GA z elityzmem przy $\tilde{\mathcal{P}} = 100$ najlepsze $\bar{\epsilon} = 1,17\%$ uzyskano dla $\zeta = 3$. W tym przypadku (#5) nie ma statystycznie istotnej różnicy w porównaniu z $\zeta = 4$.

Zwiększenie rozmiaru turnieju jest szczególnie zasadne w przypadku GA bez elityzmu, ponieważ pozwala utrzymać napór selekcyjny i zwiększa propagację osobników najlepiej przystosowanych, doprowadzając do zbieżności procesu poszukiwań zwłaszcza przy większych rozmiarach populacji. Potwierdzają to wyniki dla $\tilde{\mathcal{P}}=200$ uzyskane $\bar{\epsilon}=0,13\%$ przy $\zeta=4$ jest statystycznie różne od wyników dla $\tilde{\mathcal{P}} = 100$ ($\bar{\epsilon} = 1,56\%$) i dla $\tilde{\mathcal{P}} = 50$ ($\bar{\epsilon} = 2,58\%$) we wszystkich przeprowadzonych testach. Podobne zjawisko przyspieszenia zbieżności wpływa korzystnie na GA z elityzmem chociaż tutaj efekt nie jest istotny statystycznie. W przypadku mniejszych rozmiarów populacji istotne jest zachowanie różnorodności poprzez utrzymanie $\zeta = 2$.

6.2.3 Analiza wpływu parametrów na efektywność algorytmu TS

W ramach badań przeanalizowano TS z przeszukiwaniem przestrzeni sposobów wykonania i uszeregowania podobnie jak badana procedura SA. W odróżnieniu od SA każda z pętli przeszukiwania w TS działa niezależnie tzn. w ramach bieżącego punktu w przestrzeni sposobów wykonania przeszukiwane są kolejne punkty przestrzeni kolejności uszeregowania. Procedura TS w tej formie posiada następujące parametry:




Rys. 6.16: Wpływ β na $\bar{\epsilon}$ dla TS przy $M_m = 10$ i $M_p = 10$

- jakościowe – do których można zaliczyć: rodzaj operatora zastosowanego w modyfikacji sposobu wykonania czynności, rodzaj operatora zastosowanego w modyfikacji kolejności czynności β ,
- ilościowe – do których można zaliczyć: liczbę kroków w przestrzeni uszeregowania $S_{\max}$, liczbę prób w ramach poszukiwania nowego uszeregowania $T_{\max}$, długość listy tabu dla przestrzeni uszeregowania M_p , długość listy tabu dla przestrzeni sposobów wykonania M_m , długość listy tabu dla przestrzeni uszeregowania M_p .

Modyfikację sposobu wykonania czynności przeprowadzano dla wszystkich badanych procedur TS, jako losowy wybór sposobu wykonania ze zbioru sposobów wykonania dla i -tej czynności ($\mathcal{M}_i^\omega$). Rodzaj operatora kolejnościowego może przyjmować trzy wartości: HM (mutacja Hartmanna) zgodnie z alg. 5.5 lub BM (mutacja Boctora) zgodnie z alg. 5.4 oraz MM (mutacja polegająca na losowym wyborze jednego z dwóch poprzednich operatorów z równym prawdopodobieństwem). Liczba kroków w przestrzeni uszeregowania $S_{\max}$ może przyjmować dowolną wartość naturalną większą od 0, podobnie liczba prób w otoczeniu $T_{\max}$, długości list tabu M_p i M_m . Brak parametru odpowiadającego za liczbę generowanych sąsiadów w przestrzeni sposobów wykonania wynika z ograniczenia całkowitej liczby ocenianych rozwiązań $\tilde{\Lambda} = 20\,000$. W przypadku zwiększania liczby $S_{\max}$, jednocześnie zmniejsza się liczba badanych sposobów wykonania. Poniżej przedstawiono analizę wpływu zmiany wartości powyższych parametrów na efektywność działania TS na przykładzie modeli o $\tilde{\Omega} = 30$. Pełne zestawienie wszystkich przebadanych kombinacji parametrów (uszeregowane według malejącego $\bar{\epsilon}$) wraz z podstawowymi statystykami opisującymi uzyskane wyniki znajduje się w tab. C.3 (s. 137).

Wpływ sposobu generowania sąsiedztwa na efektywność TS

W ramach badanych rodzajów operatorów kolejnościowych (technik generowania sąsiedztwa) dla potrzeb algorytmu TS wykorzystano opisane w p. 5.3.2 procedury mutacji: Hartmanna, Boctora lub mieszaną. Przebadano procedurę TS z $S_{\max} \in \{25; 50; 100\}$, $M_p = 10$, $M_m = 10$, $T_{\max} \in \{3; 6; 9\}$. Wyniki jedno-czynnikowej analizy wariancji przedstawiono w tab. D.31 (s. 177), natomiast średnie dla poszczególnych wartości parametru β i podsumowanie wyników testów *post-hoc* zestawiono w tab. D.32 (s. 177). Uzyskany wynik $\bar{\epsilon}$ w zależności od β zilustrowano na rys. 6.16. W 7 na 9 porównań dla różnych $S_{\max}$ i $T_{\max}$ najlepszy rezultat uzyskał TS z $\beta = \text{MM}$, w pozostałych przypadkach z $\beta = \text{BM}$. Różnica pomiędzy $\bar{\epsilon}$ w przypadku BM i MM jest statystycznie nieistotna we wszystkich analizowanych przypadkach. Procedura TS z HM uzyskała najwyższy i statystycznie różny od TS z pozostałymi β wynik $\bar{\epsilon}$ niezależnie od wielkości $S_{\max}$ i $T_{\max}$. Podobnie jak w przypadku SA przyczyną gorszych wyników HM wydaje się brak




Rys. 6.17: Wpływ $S_{\max}$ na $\bar{\epsilon}$ dla TS przy $M_m = 10$ i $M_p = 10$

zdolności do eksploracji dalszego otoczenia. W przypadku HM otoczenie bieżącego punktu budowane jest poprzez utworzenie wszystkich możliwych (nie więcej niż $\tilde{\Omega}-1$) uszeregowień z użyciem operatora. W przypadku BM z uszeregowania wybierana jest losowo czynność na podstawie której przeprowadzane jest generowanie otoczenia (możliwe jest wygenerowanie różnych uszeregowień na podstawie tego samego uszeregowania wyjściowego – w HM nie ma takiej możliwości). Następnie dla każdej czynności pomiędzy pierwszym poprzednikiem, a ostatnim następnikiem losowana jest nowa pozycja, każdorazowo powstaje w ten sposób nowy osobnik z otoczenia bieżącego punktu przestrzeni uszeregowień. Zgodnie z wynikami badań stosowanie MM, który łączy obydwa powyższe rodzaje otoczeń w przestrzeni uszeregowień pozwala najczęściej uzyskać najlepsze rezultaty.

Drugim elementem wpływającym na sposób generowania otoczenia w ramach przestrzeni uszeregowień jest liczba kroków $T_{\max}$. Określa ona liczbę prób jaką TS może przeprowadzić dla uzyskania sąsiada⁵. Wyniki jednoczynnikowej analizy wariancji dla czynnika $T_{\max}$ przedstawiono w tab. D.38 (s. 182), natomiast zestawienie średnich w tab. D.39 (s. 182). Uzyskane wyniki wskazują na brak istotnych statystycznie różnic we wszystkich porównaniach, co oznacza, że zmiana wartości $T_{\max}$ nie ma istotnego wpływu na jakość wyników TS w analizowanym zakresie. Wydaje się, że wynika to z braku problemów z wygenerowaniem sąsiada, który nie znajduje się na listach tabu. Przy stosunkowo niewielkich wartościach $S_{\max}$ w porównaniu do $\tilde{\Omega}$ jakie przyjęto w niniejszych badaniach może powodować to poruszanie się w ramach niewielkiego fragmentu przestrzeni uszeregowień czynności. Wprowadzenie mechanizmu łańcuchów z SA może znacznie poprawić skuteczność TS.

Ostatnim elementem mającym wpływ na intensywność przeszukiwania przestrzeni uszeregowień jest $S_{\max}$, który decyduje o liczbie uszeregowień dla których badane będą otoczenia w ramach przestrzeni uszeregowień. Wartość $S_{\max}$ jednocześnie determinuje ewaluowaną liczbę sposobów wykonania czynności. Badania przeprowadzono dla $S_{\max} \in \{25; 50; 100\}$ przy: $\beta = \{HM; BM; MM\}$, $M_m = 10$, $M_p = 10$, $T_{\max} \in \{3; 6; 9\}$. Wyniki analizy wariancji zestawiono w tab. D.33 (s. 178). Wyniki testów *post-hoc* zestawiono w tab. D.34 (s. 178). W przypadku porównań dla $\beta = HM$ stwierdzono statystycznie istotne różnice pomiędzy $\bar{\epsilon}$. W pozostałych porównaniach jedynie dla $\beta = BM$ i $T_{\max} = 9$ oraz $\beta = MM$ i $T_{\max} = 3$ wyniki wskazują na statystycznie istotne różnice w uzyskanym poziomie $\bar{\epsilon}$. We wszystkich porównaniach z wyjątkiem #7 najlepszy średni $\bar{\epsilon}$ uzyskano dla $S_{\max} = 25$, najwyższy natomiast poziom $\bar{\epsilon}$ dla $S_{\max} = 100$.

⁵Brak możliwości wygenerowania sąsiada nastąpi np. w sytuacji, gdy dla BM wylosowana czynność startowa będzie posiadała jednego poprzednika i jednego następnika. W takim przypadku nie istnieje możliwość dokonania zmiany w uszeregowaniu zgodnie z procedurą BM, która zakłada przeniesienie losowo wybranej czynności spośród pierwszego poprzednika i ostatniego następnika, w tym przypadku jest to wyłącznie czynność od której rozpoczynamy budowanie sąsiada (por. alg. 5.4). W przypadku HM nie istnieje taka możliwość, za wyjątkiem projektu, w którym każda czynność ma co najwyżej jeden następnik i jeden poprzednik.



Rys. 6.18: Wpływ M_m na $\bar{\epsilon}$ dla TS przy $T_{\max} = 5$ i $M_p = 10$

Wskazuje to na korzystny efekt przesunięcia ciężaru poszukiwań z przestrzeni uszeregowania do przestrzeni sposobów wykonania czynności.

Wpływ długości list tabu na efektywność TS


Analizowany TS posiada dwie listy tabu: dla przestrzeni uszeregowania czynności oraz dla przestrzeni sposobów wykonania. Ograniczenie długości każdej z list pozwala sterować procesem poszukiwania umożliwiając po określonej liczbie iteracji powrót do odwiedzonego już punktu w przestrzeni poszukiwań. W celu weryfikacji hipotezy o wpływie długości listy tabu na skuteczność TS przebadano działanie algorytmu dla $M_m \in \{10; 50; 100\}$ przy pozostałych parametrach: $\beta = \{\text{HM}; \text{BM}; \text{MM}\}$, $S_{\max} \in \{10; 20; 40\}$, $M_p \in \{10; 50\}$, $T_{\max} = 5$. Wyniki analizy wariancji zestawiono w tab. D.35 (s. 179), natomiast zestawienie $\bar{\epsilon}$ wraz z wynikami testów *post-hoc* przedstawiono w tab. D.36 (s. 180). Wyniki wskazują na brak istotnych statystycznie różnic dla przebadanych poziomów M_m .

Badanie wpływu długości listy tabu dla uszeregowania czynności przeprowadzono dla $M_p \in \{10; 50\}$ przy pozostałych parametrach: $\beta = \{\text{HM}; \text{BM}; \text{MM}\}$, $S_{\max} \in \{20; 40\}$, $M_m \in \{10; 50; 100\}$, $T_{\max} = 5$. Wyniki analizy wariancji przedstawiono w tab. D.37 (s. 181). Wyniki wskazują na brak istotnych statystycznie różnic dla $\beta = \text{BM}$ i MM . W przypadku HM jedynie dla $S_{\max} = 20$ i $M_m = 50$ uzyskane średnie wartości $\bar{\epsilon}$ były nieistotnie różne. W przypadku $S_{\max} = 40$ i $M_m = 50$ wartość $F(1; 538) = 3,86$ daje w efekcie $p = 0,05$. Z uwagi na wysoki poziom $\bar{\epsilon} \geq 8\%$ dla $\beta = \text{HM}$, wyniki te wskazują na niską sprawność procesu poszukiwania.

6.2.4 Analiza wpływu parametrów na efektywność algorytmu HA

Analiza wyników SA i GA wskazała na charakterystyczne cechy komplementarne tych metaheurystyk, których połączenie w jednej procedurze, może pozwolić na uzyskanie efektu synergii. W oparciu o rozwiązania zastosowane w SA i GA zbudowano prosty algorytm hybrydowy (HA), który podzielony jest na dwa etapy: eksploracji (z wykorzystaniem GA) oraz eksploatacji poprzez zastosowanie SA dla najlepszego osobnika uzyskanego w pierwszym etapie. Z uwagi na znaczny stopień parametryzacji tego rodzaju procedury zdecydowano się wykorzystać wyniki badań z p. 6.2.1 oraz p. 6.2.2. Procedura HA w tej formie posiada następujące parametry etapu GA:

- jakościowe – do których można zaliczyć: rodzaj operatora krzyżowania (α), rodzaj operatora mutacji (β), rodzaj operatora selekcji (ϕ), zastosowanie strategii elitarniej (E),



Rys. 6.19: Wpływ $\tilde{\mathcal{P}}$ na $\bar{\epsilon}$ dla HA przy $\tilde{\Lambda}_{GA} = 5\ 000$ i $\tilde{\Lambda}_{BL} = 15\ 000$ ($\beta_{SA} = BM$, $\Delta_{max} = 0,01$)

- ilościowe – do których można zaliczyć: prawdopodobieństwo zastosowania operatora krzyżowania (p_α), prawdopodobieństwo mutacji (p_β), wielkość populacji ($\tilde{\mathcal{P}}$), liczbę pokoleń (g_{max}).

oraz następujące parametry etapu SA:

- jakościowe – do których można zaliczyć: rodzaj operatora zastosowanego w modyfikacji sposobu wykonania czynności, rodzaj operatora zastosowanego w modyfikacji kolejności czynności β ,
- ilościowe – do których można zaliczyć: prawdopodobieństwo zastosowania operatora w zakresie zmiany kolejności czynności w uszeregowaniu p_p , intensywność stosowania operatora w zakresie zmiany sposobów wykonania czynności p_m , liczbę reincjalizacji (łańcuchów) poszukiwań C , liczbę kroków S , początkowy rozmiar przeszukiwanego otoczenia N , parametr h modyfikujący długość kroku algorytmu, parametr Δ_{max} ograniczający wartość T_0 .


Dodatkowo istotnymi parametrami ilościowymi związanym bezpośrednio z HA jest $\tilde{GA}$ (określające liczbę ocenianych osobników na etapie GA) i $\tilde{SA}$ (określające liczbę ocenianych rozwiązań na etapie SA) dzielące liczbę dostępnych przekształceń parametrów w harmonogram pomiędzy etap GA i etap SA. Dla zachowania porównywalności wyników z pozostałymi metaheurystykami parametry HA muszą spełnić warunek:

$$\tilde{GA} + \tilde{SA} = \tilde{\Lambda},$$


gdzie dla wszystkich badań przyjęto $\tilde{\Lambda} = 20\ 000$. W ramach badań HA przyjęto część parametrów jako stałą zgodnie z wynikami badania poszczególnych składowych. W pierwszym etapie wykorzystano elitarny GA z przyjętymi jako najkorzystniejsze w świetle przeprowadzonych eksperymentów: $\beta = MM$, $p_\beta = 0,10$, $p_\alpha = 0,90$. Wprowadzono zwiększoną wartość p_β dla wzmocnienia funkcji eksplorujących. W drugim etapie przyjęto jako najkorzystniejsze w świetle wcześniejszych eksperymentów: $p_p = 0,90$, $p_m = 0,02$, $h = 0$. Statystyki opisowe wpływu pozostałych parametrów na skuteczność HA dla modeli o $\tilde{\Omega} = 30$ przedstawiono w tab. C.4 (s. 140).

Analiza wpływu parametrów GA na efektywność HA


W ramach badań parametrów GA sprawdzono wpływ kombinacji $\tilde{\mathcal{P}}$ i g_{max} oraz α . Przeanalizowano wpływ $\tilde{\mathcal{P}}$ na $\bar{\epsilon}$ dla HA z elitarnym GA o $\tilde{GA} \in \{5\ 000; 10\ 000; 15\ 000\}$ (i odpowiednio zmiennym



Rys. 6.20: Wpływ $\tilde{\mathcal{P}}$ na $\tilde{\epsilon}$ dla HA przy $\tilde{\Lambda}_{GA} = 10\,000$ i $\tilde{\Lambda}_{BL} = 10\,000$ ($\beta_{SA} = BM$, $\Delta_{max} = 0,01$)



Rys. 6.21: Wpływ $\tilde{\mathcal{P}}$ na $\tilde{\epsilon}$ dla HA przy $\tilde{\Lambda}_{GA} = 15\,000$ i $\tilde{\Lambda}_{BL} = 5\,000$ ($\beta_{SA} = BM$, $\Delta_{max} = 0,01$)




Rys. 6.22: Wpływ C na $\bar{\epsilon}$ dla HA przy $\tilde{\Lambda}_{GA} = 5\,000$ i $\tilde{\Lambda}_{BL} = 15\,000$ ($\beta_{SA} = BM$, $\Delta_{max} = 0,01$)

$\tilde{SA}$), $\alpha \in \{2PX; MIX\}$, $C = 2$, $S = 3$, N zależnym od $\tilde{SA}$, $\Delta_{max} = 0,01$. Wyniki analizy wariancji dla porównań przedstawiono w tab. D.40 (s. 183), natomiast zestawienie średnich $\bar{\epsilon}$ wraz z wynikami testów *post-hoc* zawarto w tab. D.41 (s. 184). Na rys. 6.19 przedstawiono porównanie $\bar{\epsilon}$ w zależności od wielkości populacji dla $\tilde{GA} = 5\,000$, na rys. 6.20 dla $\tilde{GA} = 10\,000$, natomiast na rys. 6.21 dla $\tilde{GA} = 15\,000$. W 15 porównaniach na 30 najniższy poziom $\bar{\epsilon}$ uzyskano dla $\tilde{P} = 200$, we wszystkich pozostałych wynik uzyskany przez HA był jednorodny z najlepszym przy $\tilde{P} = 200$. W kolejnych 10 porównaniach najlepszy rezultat uzyskał HA z $\tilde{P} = 250$, we wszystkich pozostałych wynik uzyskany przez HA był jednorodny z najlepszym przy $\tilde{P} = 250$. Wyniki w 11 przypadkach wskazały na brak istotnych różnic przy zmianie wielkości populacji. We wszystkich porównaniach HA z $\tilde{P} = 25$ uzyskał najwyższy $\bar{\epsilon}$ bądź jednorodny z najwyższym uzyskanym w porównaniu. Analiza wykresów wskazuje wyraźnie na korzystny efekt zwiększenia $\tilde{P}$, co wynika z postawionym przed tym etapem zadania odnalezienia najkorzystniejszego fragmentu przestrzeni parametrów dla dalszej eksploatacji przez SA. Jedynie w przypadku $\tilde{GA} = 5\,000$ zwiększanie $\tilde{P}$ powyżej 250 powoduje wzrost $\bar{\epsilon}$, co wynika z koniecznego spadku g_{max} dla zachowania $\tilde{GA}$. Etap GA nie zdąży zakończyć eksploracji i wskazać właściwego punktu dla startu SA.

Badania wpływu rodzaju operatora krzyżowania, który jest odpowiedzialny za eksplorację w GA ograniczono do $\alpha \in \{2PX; MIX\}$ przy: $\tilde{GA} \in \{5\,000; 10\,000; 15\,000\}$ (i odpowiednio zmiennym $\tilde{SA}$), $\tilde{P} \in \{25; 50; 100; 200; 250; 500\}$, $C = 2$, $S = 3$, N zależne od $\tilde{SA}$, $\Delta_{max} = 0,01$. Wyniki analizy wariancji wraz z porównaniem średnich $\bar{\epsilon}$ przedstawiono w tab. D.47 (s. 191). W jednym przypadku ($\tilde{GA} = 5\,000$ i $\tilde{P} = 500$) HA z MIX uzyskał mniejsze $\bar{\epsilon} = 0,37\%$ od 2PX ($\bar{\epsilon} = 0,39\%$), w pozostałych mniejszy $\bar{\epsilon}$ uzyskuje HA z 2PX. W większości analizowanych przypadków (za wyjątkiem #4) różnica pomiędzy uzyskanym $\bar{\epsilon}$ jest statystycznie nieistotna. W przypadku $\tilde{GA} = 10\,000$ przy $\tilde{P} = 250$ i 500, oraz dla $\tilde{GA} = 15\,000$ przy $\tilde{P} = 200$ i 500, statystycznie istotnie ($p \leq 0,035$ w teście Welcha wymienionych porównań: #11, #12, #16, #18) niższą wartość $\bar{\epsilon}$ uzyskał HA z 2PX.

Analiza wpływu parametrów BL na efektywność HA

Z parametrów właściwych dla etapu realizowanego przy pomocy SA przebadano wpływ: C i Δ_{max} . Przeanalizowano wyniki HA z $C \in \{1; 2; 3; 4; 5\}$ dla $\tilde{SA} = 15\,000$, $\tilde{P} \in \{25; 50; 100; 200; 250; 500\}$, $\alpha = 2PX$, $S \in \{3; 5\}$, $\Delta_{max} = 0,01$. Zestawienie rezultatów analizy wariancji znajduje się w tab. D.44 (s. 189) wraz z wynikami testów *post-hoc* w tab. D.45 (s. 189). Uzyskane $\bar{\epsilon}$ zilustrowano na rys. 6.22. We wszystkich analizowanych przypadkach najniższą wartość $\bar{\epsilon}$ uzyskuje HA z $C = 2$ niezależnie od wartości pozostałych parametrów. Różnica wyniku $\bar{\epsilon}$ pomiędzy HA z $C = 1$ i $C = 2$ jest statystycznie nieistotna we wszystkich przypadkach. Przy mniejszych wielkościach populacji ($\tilde{P} \leq 50$) wyniki uzyskane dla $C = 1$



Rys. 6.23: Wpływ $\tilde{\Lambda}_{GA}$ i $\tilde{\Lambda}_{SA}$ na $\bar{\epsilon}$ dla HA przy $C=2$ ($\alpha_{GA} = 2PX$, $\beta_{SA} = BM$, $\Delta_{max} = 0,01$)


lub 2 są statystycznie istotnie lepsze niż przy pozostałych badanych wielkościach. Z uwagi na ograniczenie funkcji eksploracyjnych, które zostały przeniesione na pierwszy etap HA, kluczowym elementem jest zapewnienie odpowiednio długiego łańcucha poszukiwań, szczególnie w sytuacji, gdy znacznie zmniejsza się $\tilde{SA}$ i ewentualne zwiększenie C spowoduje konieczność ograniczenia S i N .

Analiza wpływu $\tilde{GA}$ i $\tilde{BL}$ na efektywność HA

W ramach badań przeanalizowano również wpływ podziału ograniczonej liczby możliwych ewaluacji pomiędzy etap GA i etap SA, co powinno zapewnić właściwą równowagę pomiędzy eksploracją i eksploatacją w procesie poszukiwania rozwiązania. Badania wpływu $\tilde{GA}$ i $\tilde{SA}$ na $\bar{\epsilon}$ dla HA przeprowadzono przy: $(C; S) \in \{(1; 3); (1; 5); (1; 10); (2; 3); (2; 5); (2; 10)\}$, $\tilde{P} \in \{25; 50; 100; 200; 250; 500\}$, $\alpha \in \{2PX; MIX\}$, $\Delta_{max} = 0,01$. Wartość N dobrana jest w sposób zapewniający ocenę $\tilde{SA}$ rozwiązań. Podobnie wartość g_{max} ustalana jest w sposób zapewniający ocenę $\tilde{GA}$ rozwiązań. Wyniki analizy wariancji uzyskanych $\bar{\epsilon}$ zestawiono w tab. D.42 (s. 185), natomiast wyniki testów *post-hoc* znajdują się w tab. D.43 (s. 187). Wielkości średniego $\bar{\epsilon}$ uzyskane w badaniu dla $C = 1$ i $\alpha_{GA} = 2PX$ zilustrowano na rys. 6.24, natomiast dla $C = 2$ i $\alpha_{GA} = 2PX$ na rys. 6.23. W przypadku $C = 1$ wraz ze spadkiem $\tilde{SA}$ wymagane jest zmniejszanie liczby kroków S dla zachowania wystarczającej długości trajektorii poszukiwań. W przypadku $C = 1$ najniższy poziom $\bar{\epsilon}$ występuje dla $\tilde{GA} = 10\ 000$ przy $S = 3$. W przypadku $S = 5$ uzyskane $\bar{\epsilon}$ jest najniższe przy $\tilde{P} \leq 100$ dla $\tilde{GA} = 5\ 000$, natomiast przy $\tilde{P} \geq 200$ wartość $\bar{\epsilon}$ jest najniższa dla $\tilde{GA} = 10\ 000$. Przy dalszym podnoszeniu liczby kroków do $S = 10$ jedynie przy $\tilde{P} = 25$ najlepszy rezultat uzyskano dla $\tilde{GA} = 10\ 000$, dla pozostałych wielkości populacji najniższy $\bar{\epsilon}$ uzyskano przy $\tilde{GA} = 15\ 000$, co wynika z konieczności przejścia funkcji eksploatujących przez GA. Podobnie dla $C = 1$ widać konieczność zwiększania $\tilde{GA}$ w przypadku zwiększania liczby S , chociaż w przypadku $C = 1$ jedynie $S = 5$ i $\tilde{P} = 500$ uzasadnia zwiększenie udziału GA w procesie poszukiwania do $\tilde{GA} = 15\ 000$. Natomiast podobnie jak dla $C = 2$ w przypadku $C = 1$ przy $S = 3$ dla $\tilde{P} \leq 200$ najniższą wartość $\bar{\epsilon}$ uzyskuje HA dla $\tilde{GA} = 5\ 000$. Jest to jednocześnie najniższy poziom $\bar{\epsilon} = 0,34\%$ w porównaniach. Wyniki testu HSD wskazują, że wynik ten jest jednorodny z $\bar{\epsilon} = 0,37\%$ dla $\tilde{GA} = 10\ 000$ i istotnie różny od $\bar{\epsilon} = 0,49\%$ dla $\tilde{GA} = 15\ 000$.

6.3 Analiza porównawcza skuteczności wybranych metaheurystyk

W niniejszym punkcie przedstawiono wyniki eksperymentów obliczeniowych dla modeli o zróżnicowanej liczbie czynności. Badania przeprowadzono dla wybranych metaheurystyk SA, GA, TS, HA. W każdym



Rys. 6.24: Wpływ $\tilde{\Lambda}_{GA}$ i $\tilde{\Lambda}_{SA}$ na $\bar{\epsilon}$ dla HA przy $C=1$ ($\alpha_{GA} = 2PX$, $\beta_{SA} = BM$, $\Delta_{max} = 0,01$)

przypadku analizowano wyniki metaheurystyk z kombinacją parametrów, która zapewniła najniższy poziom $\bar{\epsilon}$ w badaniach dla modeli o $\tilde{\Omega}=30$ przedstawionych w p. 6.2. Parametry metaheurystyk zestawione są oznaczone #1 w tabelach: dla SA w tab. C.1 (s. 120), dla GA w tab. C.2 (s. 126), dla TS w tab. C.3 (s. 137), dla HA w tab. C.4 (s. 140).

6.3.1 Analiza porównawcza skuteczności względnej wybranych metaheurystyk

W niniejszym punkcie przedstawiono analizę porównawczą wybranych metaheurystyk dla grupy modeli o $\tilde{\Omega} \in \{30; 60; 90\}$, $NC \in \{1,5; 1,8; 2,1\}$, $RS^v \in \{0,3; 0,5; 0,7\}$, $RS^p \in \{0,3; 0,5; 0,7\}$. Porównanie skuteczności wszystkich badanych metod przeprowadzono za pomocą analizy wariancji i następnie w przypadku odrzucenia hipotezy o równości średnich sprawdzenia istotnych różnic za pomocą testów *post-hoc*. Z uwagi na bardzo silny wpływ liczby czynności w projekcie na zaobserwowany $\bar{\epsilon}$ (por.: p. 6.3.3) analizę wariancji przeprowadzono w 3 grupach w zależności od $\tilde{\Omega}$. Rozkład surowych wartości $\bar{\epsilon}$ istotnie odbiegały od rozkładu normalnego w większości badanych prób. Jedynie w próbie dla TS i $\tilde{\Omega} = 90$ zaobserwowano rozkład zgodny z normalnym (Shapiro-Wilk: $W = 0,988$, $p = ,026$ oraz Lilliefors: $d = 0,031$, $p > 0,20$). Ze względu na prawoskośny charakter obserwowanych rozkładów (dodatnia skośność) zbadano wpływ trzech rodzajów przekształceń zmiennej $\bar{\epsilon}$ dla zmniejszenia skośności rozkładu oraz kurtozy: przekształcenia logarytmicznego postaci $x = \ln(\bar{\epsilon} + 1)$, przekształcenia wykładniczego $x = \bar{\epsilon}^a$, przy $a = \frac{1}{4}$ i $a = \frac{1}{2}$. Uzyskane wartości współczynnika skośności oraz kurtozy przedstawiono w tab. 6.3.

Po zastosowaniu przekształcenia logarytmicznego rozkłady większości prób zbliżyły się do rozkładu normalnego, jednak część z nich nadal była istotnie prawoskośna, natomiast przekształcenie wykładnicze dla $a = \frac{1}{4}$ pozwoliło uzyskać zgodność z rozkładem normalnych dla prób z HA jednak jednocześnie spowodowało lewoskośność dla wyników pozostałych metod (wyniki uzyskane dla HA są znacznie silniej prawoskośne od pozostałych rozkładów). W efekcie przyjęto przekształcenie wykładnicze z $a = \frac{1}{2}$, które pozwoliło na uzyskanie najniższych co do wartości bezwzględnej współczynników skośności za wyjątkiem prób dla HA. Z uwagi na stwierdzone odstępstwa od spełnienia założeń do ANOVA przez HA (a niemożliwe do pominięcia w niniejszej analizie) oraz jednorodności wariancji w próbach poza testami parametrycznymi dla zmiennej $\sqrt{\bar{\epsilon}}$ dla weryfikacji poprawności wniosków przeprowadzono dodatkowo test mediany i ANOVA rang Kruskala-Wallisa. W przypadku odrzucenia hipotezy o równości median w próbach przeprowadzono wielokrotne porównania średnich rang dla stwierdzenia braku istotnych różnic w zaobserwowanych medianach $\bar{\epsilon}$.

We wszystkich porównaniach stwierdzono brak spełnienia założenia o jednorodności wariancji ($p < 0,001$ dla każdego porównania w teście Levene'a). Zastosowano testy odporne na niespełnienie założenia o

$\tilde{\Omega}$	MH	współczynnik skośności dla				kurtoza dla			
		$\bar{\epsilon}$	$\ln(\bar{\epsilon} + 1)$	$\sqrt{\bar{\epsilon}}$	$\sqrt[4]{\bar{\epsilon}}$	$\bar{\epsilon}$	$\ln(\bar{\epsilon} + 1)$	$\sqrt{\bar{\epsilon}}$	$\sqrt[4]{\bar{\epsilon}}$
30	GA	1,66	0,68	0,36	-0,79	3,39	0,09	0,08	1,43
30	HA	2,59	1,61	0,90	-0,38	7,92	2,54	0,65	-0,37
30	SA	2,07	1,06	0,37	-0,87	6,23	1,06	0,00	0,32
30	TS	0,57	-0,57	-0,13	-0,55	0,55	0,39	0,02	0,56
60	GA	0,69	-0,72	-0,47	-2,16	1,67	1,57	1,84	12,76
60	HA	10,04	5,91	4,14	2,62	125,01	45,41	22,13	5,92
60	SA	1,58	0,27	0,02	-1,11	3,72	-0,56	-0,32	0,43
60	TS	0,50	-0,15	0,15	-0,02	0,06	-0,29	-0,27	-0,31
90	GA	0,72	-0,78	-0,13	-0,78	1,98	3,51	1,75	4,19
90	HA	9,40	9,21	8,32	7,44	90,28	86,40	70,92	55,84
90	SA	0,61	-0,60	-0,50	-2,29	0,15	0,37	0,77	8,63
90	TS	1,58	0,27	0,02	-1,11	3,72	-0,56	-0,32	0,43

Tab. 6.3: Wpływ przekształcenia logarytmicznego i wykładniczego zmiennej $\bar{\epsilon}$ na wartości wybranych parametrów kształtu rozkładu

jednorodności wariancji. Dla $\tilde{\Omega} = 30$ w zarówno w teście Welcha ($F_W(3; 593) = 778,69$, $p < 0,001$) jak i w teście Browna-Forsythe'a ($F_{BF}(3; 939) = 1081,14$, $p < 0,001$) nie potwierdzono hipotezy o równości wartości średnich $\sqrt{\bar{\epsilon}}$ pomiędzy badanymi metodami. Wyniki testów *post-hoc* wskazują na istotne statystycznie różnice w uzyskanym $\sqrt{\bar{\epsilon}}$ pomiędzy wszystkimi metodami.

Dla $\tilde{\Omega} = 60$ zarówno w teście Welcha ($F_W(3; 563) = 4132,83$, $p < 0,001$) jak i w teście Browna-Forsythe'a ($F_{BF}(3; 848) = 3047,85$, $p < 0,001$) nie potwierdzono hipotezy o równości wartości średnich $\sqrt{\bar{\epsilon}}$ pomiędzy badanymi metodami. Wyniki testów *post-hoc* wskazują na istotne statystycznie różnice w uzyskanym $\sqrt{\bar{\epsilon}}$ pomiędzy wszystkimi metodami. Dla $\tilde{\Omega} = 90$ zarówno w teście Welcha ($F_W(3; 469) = 11207,26$, $p < 0,001$) jak i w teście Browna-Forsythe'a ($F_{BF}(3; 774) = 5859,42$, $p < 0,001$) nie potwierdzono hipotezy o równości wartości średnich $\sqrt{\bar{\epsilon}}$ pomiędzy badanymi metodami. Wyniki testów *post-hoc* wskazują na istotne statystycznie różnice w uzyskanym $\sqrt{\bar{\epsilon}}$ pomiędzy wszystkimi metodami.

W badaniach za pomocą testów nieparametrycznych stwierdzono dla $\tilde{\Omega} = 30$ brak podstaw do przyjęcia hipotezy o równości median $\bar{\epsilon}$ w grupie badanych metaheurystyk zarówno w teście mediany: $\chi^2(3) = 417,27$, $p < 0,001$, jak i w teście Kruskala-Wallisa: $H(3; N = 1080) = 647,73$ $p < 0,001$. W badaniach za pomocą testów nieparametrycznych stwierdzono dla $\tilde{\Omega} = 60$ brak podstaw do przyjęcia hipotezy o równości $\bar{\epsilon}$ w grupie badanych metaheurystyk zarówno w teście mediany: $\chi^2(3) = 713,99$, $p < 0,001$, jak i w teście Kruskala-Wallisa: $H(3; N = 1080) = 935,10$ $p < 0,001$. W badaniach za pomocą testów nieparametrycznych stwierdzono dla $\tilde{\Omega} = 90$ brak podstaw do przyjęcia hipotezy o równości $\bar{\epsilon}$ w grupie badanych metaheurystyk zarówno w teście mediany: $\chi^2(3) = 739,23$, $p < 0,001$, jak i w teście Kruskala-Wallisa: $H(3; N = 1080) = 977,58$ $p < 0,001$. Jedynie w przypadku $\tilde{\Omega} = 30$, wyniki uzyskane przez HA i SA są statystycznie jednorodne: $z = 2,40$, $p = 0,100$. W pozostałych przypadkach wyniki wszystkich porównań pomiędzy badanymi metaheurystykami pozwalają odrzucić hipotezę o równości uzyskanych $\bar{\epsilon}$.





Zarówno w testach parametrycznych (Tukey, Games-Howell, Tamhane), jak i nieparametrycznych (Kruskal-Wallis) uzyskano następujące grupy o statystycznie jednorodnym $\bar{\epsilon}$ na przyjętym poziomie istotności $\alpha = 0,05$:

- dla $\tilde{\Omega}=30$: [HA | SA] [GA] [TS]
- dla $\tilde{\Omega}=60$: [HA] [SA] [GA] [TS]
- dla $\tilde{\Omega}=90$: [HA] [SA] [GA] [TS]

Zarówno w testach parametrycznych, jak i w testach nieparametrycznych potwierdzono brak podstaw do przyjęcia hipotezy o jednorodności uzyskanych $\bar{\epsilon}$ dla poszczególnych metaheurystyk. W ramach testów

post-hoc i testów porównań opartych na rangach wykazano statystycznie istotne różnice w skuteczności poszczególnych metaheurystyk. Najskuteczniejszą metodą jest algorytm hybrydowy, który uzyskał najmniejszy $\bar{\epsilon}$, a dla problemów o liczbie czynności powyżej 30, wyznaczał najlepsze odnalezione rozwiązania.

Na rys. 6.25 przedstawiono porównanie $\bar{\epsilon}$ w zależności od zaawansowania procesu poszukiwania (wyrażonego jako liczba wygenerowanych i ocenionych harmonogramów $\tilde{\Lambda}$) dla $\tilde{\Omega} \in \{10; 30; 60; 90\}$. Dla $\tilde{\Omega} = 10$ widać, że najszybciej rozwiązania bliskie optymalnym odnalazły algorytmy GA i HA, który w pierwszym etapie korzysta z GA. W przypadku SA widać stagnację w procesie poszukiwań pomiędzy $\tilde{\Lambda} = 2\ 000$ i $5\ 000$, która może być charakterystyczna z uwagi na ograniczenie mechanizmu wychodzenia z lokalnych optimów w ramach jednego łańcucha, przy kolejnych krokach. Wyjście ze stagnacji możliwe jest po zmianie wartości S , co powoduje zmianę wartości parametrów w ramach sposobu wykonania czynności. Natomiast dla problemów o większej liczbie czynności, gdzie przestrzeń uszeregowień jest znacznie większa i wymagają ewaluacji większej liczby punktów w tej przestrzeni SA dochodzi znacznie szybciej rozwiązań bliskich najlepszym odnalezionym. Algorytm TS potrzebuje najdłuższej trajektorii poszukiwań, aby odnaleźć rozwiązania zbliżone do konkurencyjnych metod. Przykładowo dla $\tilde{\Omega} = 60$ rozwiązanie na poziomie $\bar{\epsilon} = 20\%$ algorytm SA odnajduje po weryfikacji mniej niż $1\ 000$ harmonogramów, GA i HA po około $2\ 000$, natomiast TS po około $6\ 000$. Osiągnięcie $\bar{\epsilon}$ na poziomie 10% możliwe jest dla SA po weryfikacji około $1\ 000$ rozwiązań, natomiast GA i HA potrzebują $\tilde{\Lambda} = 5\ 000$. TS nie osiąga tego wyniku w $20\ 000$, chociaż trajektoria poszukiwań wskazuje na potencjalną możliwość osiągnięcia $\bar{\epsilon} = 10\%$ jednak wymagałoby to znacznie większej liczby sprawdzonych rozwiązań. W przypadku HA na trajektorii rozwiązań zaobserwować można charakterystyczną zmianę po zrealizowaniu $5\ 000$ punktów związaną ze zmianą metody na SA. Można wyraźnie zauważyć, że wykorzystanie GA w pierwszym etapie obniża skuteczność (GA uzyskuje istotnie gorszy rezultat od SA) jednak pozwala SA na start w drugim etapie od bardziej atrakcyjnego fragmentu przestrzeni poszukiwań, który nie jest wyeksploatowany przez GA. W efekcie HA w etapie SA uzyskuje już po niecałych $3\ 000$ ewaluacji niższy poziom $\bar{\epsilon}$, niż samodzielny SA. Zjawisko to widać wyraźnie dla trudniejszych problemów o $\tilde{\Omega} = 60$ i 90 .



Rys. 6.25: Porównanie $\bar{\varepsilon}$ w zależności od zaawansowania poszukiwań ($\tilde{\lambda}$) wybranych metod dla grupy modeli o $\tilde{\Omega} \in \{10; 30; 60; 90\}$

$\bar{RS}^p$	$\bar{RS}^v$	$\bar{\epsilon}$ dla $\tilde{\Lambda}=5\ 000$				$\bar{\epsilon}$ dla $\tilde{\Lambda}=10\ 000$				$\bar{\epsilon}$ dla $\tilde{\Lambda}=20\ 000$			
		SA	GA	HA	TS	SA	GA	HA	TS	SA	GA	HA	TS
0,3	0,3	0,00	0,00	0,01	0,04	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00
0,3	0,5	0,14	0,04	0,00	0,13	0,00	0,04	0,00	0,05	0,00	0,04	0,00	0,00
0,3	0,7	0,08	0,00	0,00	0,26	0,03	0,00	0,00	0,01	0,03	0,00	0,00	0,01
0,5	0,3	0,05	0,03	0,03	0,07	0,00	0,03	0,00	0,03	0,00	0,03	0,00	0,02
0,5	0,5	0,04	0,00	0,00	0,17	0,02	0,00	0,00	0,05	0,00	0,00	0,00	0,03
0,5	0,7	0,00	0,00	0,00	0,08	0,00	0,00	0,00	0,06	0,00	0,00	0,00	0,04
0,7	0,3	0,00	0,00	0,00	0,02	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
0,7	0,5	0,01	0,00	0,00	0,15	0,01	0,00	0,00	0,06	0,00	0,00	0,00	0,01
0,7	0,7	0,10	0,00	0,01	0,09	0,00	0,00	0,01	0,05	0,00	0,00	0,01	0,05
Ogółem		0,05	0,01	0,01	0,11	0,01	0,01	0,00	0,03	0,00	0,01	0,00	0,02

Tab. 6.4: Średni błąd ($\bar{\epsilon}$) dla modeli o $\tilde{\Omega} = 10$ i $NC = 1,5$ po $\tilde{\Lambda} = 5\ 000$, $10\ 000$ i $20\ 000$ zbudowanych rozwiązań

6.3.2 Analiza skuteczności względem rozwiązań optymalnych dla $\tilde{\Omega} = 10$

W niniejszym punkcie przedstawiono analizę porównawczą wybranych metaheurystyk dla grupy modeli o $\tilde{\Omega} = 10$ oraz $NC = 1,5$, $RS^v \in \{0,3; 0,5; 0,7\}$, $RS^p \in \{0,3; 0,5; 0,7\}$. Ogółem 90 modeli po 10 dla każdego zestawu parametrów. Dla problemów tych określono globalnie najlepsze rozwiązania, co pozwoli zweryfikować bezwzględną skuteczność analizowanych metaheurystyk. Analizę skuteczności oparto na dwóch kryteriach: (1) średnim błędzie odnalezionych rozwiązań od rozwiązań optymalnych oraz (2) liczbie odnalezionych rozwiązań optymalnych.

W tab. 6.4 zestawiono porównanie średniego błędu względem rozwiązań optymalnych ($\bar{\epsilon}$) dla analizowanej grupy problemów, natomiast w tab. 6.5 zestawiono liczbę odnalezionych przez algorytm rozwiązań optymalnych. Obydwie tabele zawierają porównanie wyników po 5 000, 10 000 i 20 000 zbudowanych rozwiązań. Na rys. 6.25 zilustrowano średni błąd $\bar{\epsilon}$ względem rozwiązania optymalnego dla wybranych metaheurystyk w zależności od liczby zbudowanych rozwiązań. Wyniki analizy wskazują na największą skuteczność ($\bar{\epsilon} \leq 0,01$) po 20 000 ewaluacji dla procedur SA i HA. Procedury te odnalazły również najwięcej bo 89 (na 90 rozwiązywanych problemów) rozwiązań optymalnych. O jedno mniej rozwiązanie optymalne odnalazł algorytm genetyczny, natomiast procedura TS odnalazła jedynie 82 rozwiązania optymalne.

Następnie przeanalizowano wpływ zmniejszenia liczby dozwolonych ewaluacji rozwiązań na obydwa analizowane kryteria z uwagi na brak istotnych różnic w wynikach dla $\tilde{\Lambda} = 20\ 000$, który świadczy o łatwości z jaką procedury rozwiązały zestaw problemów. Zmniejszenie liczby ewaluacji pozwoli zróżnicować wyniki oraz wskazać procedury, które potrafią rozwiązać zestaw problemów w najkrótszym czasie. W pierwszym kroku zmniejszono liczbę dopuszczalnych ewaluacji do 10 000, co spowodowało nieznaczny wzrost $\bar{\epsilon}$ w przypadku SA i TS, natomiast średni błąd dla GA nie uległ zmianie. Znacznie spadała również liczba odnalezionych rozwiązań optymalnych dla TS z 82 do 74 oraz dla SA z 89 do 85. Liczba odnalezionych rozwiązań optymalnych dla GA nie uległa zmianie. Przy dalszym zmniejszeniu dozwolonej liczby zbudowanych rozwiązań do 5 000 ponownie zaobserwowano brak zmian w wynikach GA oraz znaczne pogorszenie wyników dla SA i TS. Wyniki analizy wskazują, że algorytm genetyczny w najkrótszym czasie 5 000 ewaluacji odnalazł 88 rozwiązań optymalnych na 90 możliwych. W tym samym czasie SA odnalazł 77 optimów, co stanowi 86% wszystkich problemów, natomiast TS jedynie w 65% przypadków rozwiązał problem optymalnie. Stwierdzona zdolność algorytmu genetycznego do szybkiej eksploracji przestrzeni rozwiązań, potwierdza zasadność wykorzystania tego rodzaju procedury na pierwszym etapie algorytmu hybrydowego.

$\bar{R}\bar{S}^p$	$\bar{R}\bar{S}^v$	$\tilde{\lambda}_{opt}$ dla $\tilde{\Lambda}=5\ 000$				$\tilde{\lambda}_{opt}$ dla $\tilde{\Lambda}=10\ 000$				$\tilde{\lambda}_{opt}$ dla $\tilde{\Lambda}=20\ 000$			
		SA	GA	HA	TS	SA	GA	HA	TS	SA	GA	HA	TS
0,3	0,3	9	10	9	8	9	10	10	9	10	10	10	10
0,3	0,5	8	9	9	6	10	9	10	8	10	9	10	10
0,3	0,7	8	10	10	6	9	10	10	9	9	10	10	9
0,5	0,3	8	9	9	7	10	9	10	8	10	9	10	9
0,5	0,5	7	10	10	4	9	10	10	6	10	10	10	8
0,5	0,7	10	10	10	7	10	10	10	8	10	10	10	8
0,7	0,3	10	10	10	7	10	10	10	10	10	10	10	10
0,7	0,5	9	10	10	7	9	10	10	7	10	10	10	9
0,7	0,7	8	10	9	7	9	10	9	9	10	10	9	9
Ogółem		77	88	86	59	85	88	89	74	89	88	89	82

Tab. 6.5: Liczba odnalezionych rozwiązań optymalnych ($\tilde{\lambda}_{opt}$) dla modeli o $\tilde{\Omega} = 10$ i $NC = 1,5$ po $\tilde{\Lambda} = 5\ 000$, $10\ 000$ i $20\ 000$ zbudowanych rozwiązań

6.3.3 Analiza wpływu parametrów problemu ($\tilde{\Omega}$, $\bar{R}\bar{S}^p$, $\bar{R}\bar{S}^v$, NC) na skuteczność metaheurystyk

W niniejszym punkcie przedstawiono analizę porównawczą wpływu parametrów problemu ($\tilde{\Omega}$, $\bar{R}\bar{S}^p$, $\bar{R}\bar{S}^v$, NC) na skuteczność wybranych metaheurystyk (SA, GA, TS, HA) dla grupy modeli o $\tilde{\Omega} \in \{30; 60; 90\}$, $NC \in \{1,5; 1,8; 2,1\}$, $\bar{R}\bar{S}^v \in \{0,3; 0,5; 0,7\}$, $\bar{R}\bar{S}^p \in \{0,3; 0,5; 0,7\}$. Dla sprawdzenia wpływu poszczególnych parametrów badanych problemów na trudność zadania przeprowadzono wieloczynnikową analizę wariancji dla każdej z metod.

Z uwagi na częstą prawoskośność danych surowych ($\bar{\epsilon}$) analizę oparto na $\sqrt{\bar{\epsilon}}$ (por.: p. 6.3.1). Rozkład zmiennej $\sqrt{\bar{\epsilon}}$ spełnia w stopniu wystarczającym założenie o normalności dla większości analizowanych przypadków. W przypadku $\sqrt{\bar{\epsilon}}$ dla grup SA, GA i TS występują niewielkie odstępstwa od rozkładu normalnego i nie powinny mieć istotnego wpływu na wnioski z analizy. Jedynie w przypadku HA, rozkład zarówno $\bar{\epsilon}$, jak i $\sqrt{\bar{\epsilon}}$ znacznie odbiega od rozkładu normalnego (Shapiro-Wilk: $W < 0,95$, $p < 0,001$ oraz Lilliefors: $d > 0,10$, $p < 0,01$). Wynika to z relatywnie (w porównaniu do innych badanych metod) wysokiej i powtarzalnej skuteczności HA w rozwiązywaniu problemów i wyznaczenia znacznej większości najlepszych znanych rozwiązań dla modeli o $\tilde{\Omega} = 60$ i $\tilde{\Omega} = 90$, które są podstawą kalkulacji $\bar{\epsilon}$. Wnioskowanie na podstawie ANOVA dla tego przypadku wymaga szczególnej ostrożności, gdyż rozkłady $\sqrt{\bar{\epsilon}}$ bardzo znacznie odbiegają od rozkładu normalnego w tych grupach – są silnie prawoskośne (np. współczynnik skośności = 8,32 dla $\tilde{\Omega} = 60$ oraz 4,14 dla $\tilde{\Omega} = 90$) o wysokiej kurtozie (np. 22,13 dla $\tilde{\Omega} = 60$ oraz 70,92 dla $\tilde{\Omega} = 90$).

W tab. 6.6 przedstawiono wyniki ANOVA dla efektów głównych oraz dla interakcji czynników zaobserwowane w trakcie eksperymentów z wykorzystaniem GA. Zaobserwowano dwie istotne statystycznie interakcje czynników: liczby czynności i ścisłości ograniczeń dostępności zasobów odnawialnych ($\bar{R}\bar{S}^p \times \tilde{\Omega}$) oraz liczby czynności i struktury ograniczeń kolejnościowych ($NC \times \tilde{\Omega}$). Przy czym zarówno wpływ $\bar{R}\bar{S}^p \times \tilde{\Omega}$ na uzyskany $\sqrt{\bar{\epsilon}}$ jak i wpływ $NC \times \tilde{\Omega}$ ($\eta^2 = 0,004$) są znikome co do siły oddziaływania (wartości $\eta^2 = 0,004$ i $\eta^2 = 0,005$ odpowiednio). Poza NC, którego istotność wpływu na uzyskane $\sqrt{\bar{\epsilon}}$ jest na poziomie tendencji statystycznej ($F(2; 809) = 2,70$, $p = 0,068$), efekty główne pozostałych czynników: $\tilde{\Omega}$, $\bar{R}\bar{S}^p$, $\bar{R}\bar{S}^v$, są statystycznie istotne ($p < 0,001$). Najsilniejszy efekt główny zaobserwowano dla czynnika $\tilde{\Omega}$ ($\eta^2 = 0,752$) przy wpływie słabym (choć istotnym) ograniczeń zasobowych $\eta^2 = 0,013$ dla $\bar{R}\bar{S}^p$ i pomijalnym ($\eta^2 = 0,003$) dla $\bar{R}\bar{S}^v$. Zaobserwowane η^2 wpływu efektów głównych i interakcji wskazuje, że dla GA największą trudnością jest ponadwykładniczy przyrost liczby dopuszczalnych kombinacji parametrów wraz ze wzrostem liczby czynności. Wpływ ograniczeń zasobów odnawialnych jest znacznie silniejszy od wpływu ograniczeń zasobów nieodnawialnych, co może wskazywać na większą wagę przeszukiwania przestrzeni uszeregowania, niż przestrzeni sposobów wykonania czynności.

W tab. 6.7 przedstawiono wyniki ANOVA dla efektów głównych oraz dla interakcji czynników zaobserwowane w trakcie eksperymentów z wykorzystaniem SA. Zaobserwowano słaby ($\eta^2 = 0,016$) efekt interakcji czwartego poziomu $\bar{R}\bar{S}^p \times \bar{R}\bar{S}^v \times NC \times \tilde{\Omega}$, oraz trzy istotne statystycznie, choć bardzo słabe

Źródło zmienności	SS	df	MS	F	p	η^2	η_p^2
▷ $\bar{R}\bar{S}^\rho$	6,76	2	3,38	22,85	<0,001	0,013	0,059
▷ $\bar{R}\bar{S}^\nu$	1,32	2	0,66	4,45	0,012	0,003	0,012
▷ $\tilde{\Omega}$	391,89	2	195,95	1325,36	<0,001	0,752	0,784
NC	0,80	2	0,40	2,70	0,068	0,002	0,007
$\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu$	0,25	4	0,06	0,41	0,798	0,000	0,002
▷ $\bar{R}\bar{S}^\rho \times \tilde{\Omega}$	2,81	4	0,70	4,76	<0,001	0,005	0,025
$\bar{R}\bar{S}^\nu \times \tilde{\Omega}$	1,06	4	0,26	1,79	0,129	0,002	0,010
$\bar{R}\bar{S}^\rho \times NC$	0,92	4	0,23	1,56	0,185	0,002	0,008
$\bar{R}\bar{S}^\nu \times NC$	0,77	4	0,19	1,30	0,270	0,001	0,007
▷ $NC \times \tilde{\Omega}$	2,26	4	0,56	3,82	0,004	0,004	0,021
$\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu \times \tilde{\Omega}$	1,07	8	0,13	0,91	0,510	0,002	0,010
$\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu \times NC$	0,77	8	0,10	0,65	0,732	0,001	0,007
$\bar{R}\bar{S}^\rho \times NC \times \tilde{\Omega}$	0,52	8	0,06	0,44	0,898	0,001	0,005
$\bar{R}\bar{S}^\nu \times NC \times \tilde{\Omega}$	0,72	8	0,09	0,61	0,768	0,001	0,007
$\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu \times NC \times \tilde{\Omega}$	1,26	16	0,08	0,53	0,931	0,002	0,012
Reszta	107,78	729	0,15				
Ogółem	520,95	809					

Tab. 6.6: Podsumowanie wyników ANOVA zmiennej zależnej $\sqrt{\epsilon}$ i zmiennych niezależnych $\tilde{\Omega}$, NC, $\bar{R}\bar{S}^\rho$, $\bar{R}\bar{S}^\nu$ dla wyników uzyskanych przez GA. Symbolem ▷ oznaczono efekty główne i efekty interakcji istotne przy $\alpha = 0,05$.

Źródło zmienności	SS	df	MS	F	p	η^2	η_p^2
▷ $\bar{R}\bar{S}^\rho$	24,99	2	12,50	57,65	<0,001	0,063	0,137
$\bar{R}\bar{S}^\nu$	0,14	2	0,07	0,33	0,716	0,000	0,001
▷ $\tilde{\Omega}$	190,21	2	95,10	438,75	<0,001	0,479	0,546
NC	0,32	2	0,16	0,75	0,474	0,001	0,002
$\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu$	0,11	4	0,03	0,12	0,975	0,000	0,001
▷ $\bar{R}\bar{S}^\rho \times \tilde{\Omega}$	2,31	4	0,58	2,67	0,031	0,006	0,014
$\bar{R}\bar{S}^\nu \times \tilde{\Omega}$	1,25	4	0,31	1,45	0,217	0,003	0,008
$\bar{R}\bar{S}^\rho \times NC$	0,15	4	0,04	0,18	0,950	0,000	0,001
▷ $\bar{R}\bar{S}^\nu \times NC$	2,92	4	0,73	3,37	0,010	0,007	0,018
▷ $NC \times \tilde{\Omega}$	2,90	4	0,72	3,34	0,010	0,007	0,018
$\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu \times \tilde{\Omega}$	0,49	8	0,06	0,28	0,972	0,001	0,003
$\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu \times NC$	2,43	8	0,30	1,40	0,193	0,006	0,015
$\bar{R}\bar{S}^\rho \times NC \times \tilde{\Omega}$	1,19	8	0,15	0,68	0,706	0,003	0,007
$\bar{R}\bar{S}^\nu \times NC \times \tilde{\Omega}$	3,19	8	0,40	1,84	0,066	0,008	0,020
▷ $\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu \times NC \times \tilde{\Omega}$	6,44	16	0,40	1,86	0,022	0,016	0,039
Reszta	158,02	729	0,22				
Ogółem	397,06	809					

Tab. 6.7: Podsumowanie wyników ANOVA zmiennej zależnej $\sqrt{\epsilon}$ i zmiennych niezależnych $\tilde{\Omega}$, NC, $\bar{R}\bar{S}^\rho$, $\bar{R}\bar{S}^\nu$ dla wyników uzyskanych przez SA. Symbolem ▷ oznaczono efekty główne i efekty interakcji istotne przy $\alpha = 0,05$.

Źródło zmienności	SS	df	MS	F	p	η^2	η_p^2
▷ $\bar{R}\bar{S}^\rho$	28,24	2	14,12	85,49	<0,001	0,024	0,190
▷ $\bar{R}\bar{S}^\nu$	47,73	2	23,87	144,50	<0,001	0,040	0,284
▷ $\tilde{\Omega}$	971,27	2	485,64	2940,30	<0,001	0,818	0,890
NC	0,15	2	0,08	0,45	0,635	0,000	0,001
▷ $\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu$	1,80	4	0,45	2,72	0,029	0,002	0,015
▷ $\bar{R}\bar{S}^\rho \times \tilde{\Omega}$	3,36	4	0,84	5,09	<0,001	0,003	0,027
$\bar{R}\bar{S}^\nu \times \tilde{\Omega}$	1,37	4	0,34	2,08	0,082	0,001	0,011
▷ $\bar{R}\bar{S}^\rho \times NC$	1,73	4	0,43	2,62	0,034	0,001	0,014
$\bar{R}\bar{S}^\nu \times NC$	1,34	4	0,34	2,03	0,089	0,001	0,011
▷ $NC \times \tilde{\Omega}$	1,69	4	0,42	2,55	0,038	0,001	0,014
▷ $\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu \times \tilde{\Omega}$	3,28	8	0,41	2,48	0,012	0,003	0,027
$\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu \times NC$	0,29	8	0,04	0,22	0,987	0,000	0,002
$\bar{R}\bar{S}^\rho \times NC \times \tilde{\Omega}$	1,72	8	0,22	1,30	0,239	0,001	0,014
$\bar{R}\bar{S}^\nu \times NC \times \tilde{\Omega}$	0,51	8	0,06	0,38	0,930	0,000	0,004
$\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu \times NC \times \tilde{\Omega}$	2,09	16	0,13	0,79	0,696	0,002	0,017
Reszta	120,41	729	0,17				
Ogółem	1186,99	809					

Tab. 6.8: Podsumowanie wyników ANOVA zmiennej zależnej $\sqrt{\epsilon}$ i zmiennych niezależnych $\tilde{\Omega}$, NC, $\bar{R}\bar{S}^\rho$, $\bar{R}\bar{S}^\nu$ dla wyników uzyskanych przez TS. Symbolem ▷ oznaczono efekty główne i efekty interakcji istotne przy $\alpha = 0,05$.

efekty interakcji drugiego poziomu: liczby czynności i ścisłości ograniczeń dostępności zasobów odnawialnych ($\bar{R}\bar{S}^\rho \times \tilde{\Omega}$), ścisłości ograniczeń dostępności zasobów nieodnawialnych i ścisłości ograniczeń kolejnościowych ($\bar{R}\bar{S}^\nu \times NC$) oraz ścisłości ograniczeń kolejnościowych i liczby czynności ($NC \times \tilde{\Omega}$). Wszystkie efekty interakcji drugiego poziomu mają podobną siłę związku z $\sqrt{\epsilon}$ ocenioną poprzez η^2 na poziomie 0,006 i 0,007. Podobnie jak w przypadku GA zaobserwowano bardzo silny efekt główny $\tilde{\Omega}$ na poziomie $\eta^2 = 0,479$, słabszy efekt główny dla $\bar{R}\bar{S}^\rho$ na poziomie $\eta^2 = 0,063$.

W tab. 6.8 przedstawiono wyniki ANOVA dla efektów głównych oraz dla interakcji czynników zaobserwowane w trakcie eksperymentów z wykorzystaniem TS. Zaobserwowano jeden istotny statystycznie, choć o pomijalnej sile ($\eta^2 = 0,003$) efekt interakcji dla $\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu \times \tilde{\Omega}$ cztery istotne statystycznie, choć równie słabe ($\eta^2 \leq 0,003$) efekty interakcji drugiego poziomu: $NC \times \tilde{\Omega}$, $\bar{R}\bar{S}^\rho \times NC$, $\bar{R}\bar{S}^\rho \times \tilde{\Omega}$ oraz $\bar{R}\bar{S}^\rho \times \bar{R}\bar{S}^\nu$. Najsilniejszy podobnie jak w przypadku opisywanych uprzednio metaheurystyk efekt główny zaobserwowano dla czynnika $\tilde{\Omega}$ na poziomie $\eta^2 = 0,818$ oraz porównywalnie silny wpływ dla ograniczeń zasobowych. Silniejszy wpływ na skuteczność TS w poszukiwaniu rozwiązań ma zmiana $\bar{R}\bar{S}^\nu$ ($\eta^2 \leq 0,040$) niż zmiana $\bar{R}\bar{S}^\rho$ ($\eta^2 \leq 0,024$). Znaczna siła wpływu $\bar{R}\bar{S}^\nu$ na $\sqrt{\epsilon}$ dla TS może wynikać ze stwierdzonej uprzednio niskiej skuteczności w przeszukiwaniu przestrzeni sposobów wykonania czynności (por. p. 6.2.3). Wpływ $\bar{R}\bar{S}^\nu$ dla SA i HA jest nieistotny statystycznie, natomiast dla GA siła wpływu wynosi $\eta_p^2 = 0,012$ przy $\eta_p^2 = 0,284$ dla TS, czyli jest ponad 20-krotnie słabsza.

W tab. 6.9 przedstawiono wyniki ANOVA dla efektów głównych oraz dla interakcji czynników zaobserwowane w trakcie eksperymentów z wykorzystaniem HA. Zaobserwowano podobnie jak w przypadku pozostałych metaheurystyk najsilniejszy ($\eta^2 = 0,371$) wpływ liczby czynności do zaplanowania. Stwierdzono również jeden efekt interakcji o sile związku na poziomie $\eta^2 = 0,018$. Pozostałe efekty główne, jak i interakcje mają słaby lub nieistotny związek z uzyskiwanym $\sqrt{\epsilon}$. Generalnie trudność problemu RCPS w badanym zakresie parametrów ma porównywalnie nieznaczny wpływ na skuteczność HA. Obserwacja ta może wynikać ze znacznego odstępstwa od założenia normalności rozkładu $\sqrt{\epsilon}$ dla HA.

Źródło zmienności	SS	df	MS	F	p	η^2	η_p^2
▸ $\bar{R}\bar{S}^p$	0,97	2	0,49	7,88	<0,001	0,012	0,021
$\bar{R}\bar{S}^v$	0,03	2	0,01	0,23	0,796	0,000	0,001
▸ $\tilde{\Omega}$	30,82	2	15,41	249,62	<0,001	0,371	0,406
NC	0,31	2	0,16	2,54	0,080	0,004	0,007
$\bar{R}\bar{S}^p \times \bar{R}\bar{S}^v$	0,07	4	0,02	0,29	0,882	0,001	0,002
▸ $\bar{R}\bar{S}^p \times \tilde{\Omega}$	1,50	4	0,38	6,07	<0,001	0,018	0,032
$\bar{R}\bar{S}^v \times \tilde{\Omega}$	0,25	4	0,06	1,02	0,395	0,003	0,006
$\bar{R}\bar{S}^p \times NC$	0,36	4	0,09	1,46	0,213	0,004	0,008
$\bar{R}\bar{S}^v \times NC$	0,25	4	0,06	0,99	0,410	0,003	0,005
▸ $NC \times \tilde{\Omega}$	0,75	4	0,19	3,05	0,016	0,009	0,016
$\bar{R}\bar{S}^p \times \bar{R}\bar{S}^v \times \tilde{\Omega}$	0,19	8	0,02	0,39	0,927	0,002	0,004
$\bar{R}\bar{S}^p \times \bar{R}\bar{S}^v \times NC$	0,47	8	0,06	0,96	0,470	0,006	0,010
$\bar{R}\bar{S}^p \times NC \times \tilde{\Omega}$	0,28	8	0,04	0,57	0,804	0,003	0,006
$\bar{R}\bar{S}^v \times NC \times \tilde{\Omega}$	0,63	8	0,08	1,29	0,248	0,008	0,014
$\bar{R}\bar{S}^p \times \bar{R}\bar{S}^v \times NC \times \tilde{\Omega}$	1,06	16	0,07	1,08	0,374	0,013	0,023
Reszta	45,00	729	0,06				
Ogółem	82,97	809					

Tab. 6.9: Podsumowanie wyników ANOVA zmiennej zależnej $\sqrt{\epsilon}$ i zmiennych niezależnych $\tilde{\Omega}$, NC, $\bar{R}\bar{S}^p$, $\bar{R}\bar{S}^v$ dla wyników uzyskanych przez HA. Symbolem ▸ oznaczono efekty główne i efekty interakcji istotne przy $\alpha = 0,05$.


6.4 Analiza wybranych kryteriów optymalizacji dla problemów o $\tilde{\Omega}=10$

Poniżej przedstawiono analizę zależności kryteriów czasowych i finansowych na przykładzie modeli o $\tilde{\Omega}=10$ w zależności od parametrów $\bar{R}\bar{S}^p$, $\bar{R}\bar{S}^v$. Dla zachowania wzajemnej porównywalności osiągniętych wartości kryterium czasowego (T) i zdyskontowanych przepływów pieniężnych (NPV) skonstruowano następujące wskaźniki oceny dla s -tego rozwiązania o wartościach kryteriów (T_s , NPV_s) przyjmując ogółem N wszystkich rozwiązań problemu (całej przestrzeni poszukiwań w ramach zdefiniowanej przestrzeni parametrów):


$$i_{NPV} = \frac{\max_{k=1,\dots,N} \{NPV_k\} - NPV_s}{\max_{k=1,\dots,N} \{NPV_k\} - \min_{k=1,\dots,N} \{NPV_k\}} \quad (6.4)$$

$$i_T = \frac{T_s - \min_{k=1,\dots,N} \{T_k\}}{\max_{k=1,\dots,N} \{T_k\} - \min_{k=1,\dots,N} \{T_k\}} \quad (6.5)$$


Celem optymalizacji jest w tym przypadku osiągnięcie minimalnej wartości zarówno i_{NPV} , jak i i_T . Na rys. 6.26 przedstawiono wartości i_{NPV} , i_T dla wszystkich rozwiązań zestawu problemów w zależności od ścisłości ograniczeń zasobowych wyrażonych poprzez $\bar{R}\bar{S}^p$ i $\bar{R}\bar{S}^v$. Odpowiednie wartości parametrów zaznaczono na wykresach. Wszystkie przedstawione problemy mają identyczne zależności kolejnościowe, różnią się jedynie ścisłością ograniczeń zasobowych. Im większy obszar pokrywają rozwiązania, tym trudniejszy od strony obliczeniowej jest prezentowany problem, ponieważ tym większy jest zbiór dopuszczalnych rozwiązań. Istotną kwestią dla określenia trudności odnalezienia rozwiązań optymalnych jest liczba rozwiązań o $i_{NPV} = 0$. Z analizy wykresów wynika, że o ile osiągnięcie $i_{NPV} = 0,5$ możliwe jest przy bardzo zróżnicowanych wartościach i_T , to osiągnięcie $i_{NPV} = 0$ możliwe jest dla wartości $i_T \in (0,0; 0,47)$ w zależności od modelu. Osiągnięcie wartości $i_{NPV} = 0$ możliwe jest dla dokładnie jednej wartości i_T , przy czym w zależności od modelu jest to od 1 do 24 punktów w przestrzeni parametrów. Na rys. 6.28 przedstawiono liczebność zakodowanych rozwiązań pozwalających uzyskać wartości i_{NPV} odpowiednio w przedziałach. Punkty przestrzeni parametrów liczone są według wszystkich kombinacji wykonalnych sposobów wykonania i uszeregowania nie naruszających ograniczeń kolejnościowych (zgodnie z przyjętą



Rys. 6.26: Rozwiązania wybranych modeli o $\tilde{\Omega}=10$ i zróżnicowanych ograniczeniach zasobowych



Rys. 6.27: Rozwiązania z rys. 6.26 dla punktu $(\mu_1, \dots, \mu_{\tilde{\Omega}})$ w przestrzeni sposobów wykonania zapewniającego optymalną wartość NPV. Zawężenie przestrzeni rozwiązań wyłącznie do uszeregowień czynności (przy optymalnym $(\mu_1, \dots, \mu_{\tilde{\Omega}})$) pokazuje istotny wpływ samego uszeregowania czynności na uzyskany wynik NPV.



Rys. 6.28: Liczebność punktów w przestrzeni parametrów w zależności od i_{NPV} dla modeli z rys. 6.26. Słupki reprezentują liczebność rozwiązań w ramach przedziałów i_{NPV} o szerokości 0,1.

reprezentacją. Rozkład liczby obserwacji zbliżony jest do rozkładu normalnego dla większości modeli. Średnio 2,4% punktów w przestrzeni poszukiwań pozwala uzyskać rozwiązanie o $i_{NPV} < 0,1$, natomiast $i_{NPV} < 0,2$ dla 12,2% punktów w przestrzeni parametrów. Analiza zależności i_T i i_{NPV} wskazała, że:

- w 42 przypadkach spośród 90 analizowanych problemów zmniejszenie wartości i_{NPV} z przedziału $(0,0;0,1)$ do wartości optymalnej wiąże się ze wzrostem i_T ,
- średni rozstęp i_T dla $i_{NPV} < 0,1$ wynosi 0,06 (maksymalny 0,14) – co oznacza, że optymalizując NPV, możliwe jest uzyskanie znacznie odbiegającego od optymalnego czasu zakończenia projektu,
- średni rozstęp i_{NPV} dla $i_T \geq 0,1$ wynosi 0,20 (maksymalny 0,36) – co oznacza, że optymalizacja czasu zakończenia projektu, nie jest jednoznaczna z uzyskaniem optymalnych lub nawet suboptymalnych wartości NPV,
- we wszystkich badanych przypadkach zmniejszenie wartości i_T z przedziału $(0,9;1,0)$ do wartości optymalnej wiąże się ze wzrostem i_{NPV} ,
- rozwiązania optymalne ze względu na czas zakończenia realizacji projektu stanowią w zależności od modelu od 0,01% do 21,86% wszystkich rozwiązań (średnio 1,84%),
- rozwiązania optymalne ze względu na wartość NPV z realizacji projektu stanowią w zależności od modelu od 0,0003% do 0,14% wszystkich rozwiązań (średnio 0,01%).

Powyższe obserwacje prowadzą do wniosku, że pomimo istnienia silnej dodatniej korelacji, optymalizacja czasu zakończenia realizacji projektu, nie jest jednoznaczna z optymalizacją uzyskanych korzyści ekonomicznych. Ponadto odnalezienie rozwiązań optymalnych ze względu na kryterium NPV jest trudniejsze od odnalezienia rozwiązań optymalnych ze względu na kryterium czasu zakończenia. W związku z powyższym i mając na względzie powszechność kryterium terminu zakończenia projektu, którego minimalizacja może wiązać się z uzyskaniem niewymiernych lub niemożliwych do ujęcia w modelu oceny harmonogramu korzyści istnieją przesłanki do uwzględnienia w dalszych badaniach możliwości prowadzenia optymalizacji wielo-kryterialnej.

6.5 Podsumowanie i ocena badanych metod

W ramach przeprowadzonych eksperymentów obliczeniowych zweryfikowano możliwość zastosowania wybranych metaheurystyk w harmonogramowaniu przedsięwzięć o charakterze projektowym. Zbadano funkcjonowanie i wyniki działania trzech wybranych rodzajów metaheurystyk homogenicznych: GA, SA i TS oraz algorytmu hybrydowego powstałego z połączenia GA i SA. Poza oceną skuteczności obliczeniowej, przy ocenie użyteczności powyższych algorytmów należy ocenić je również w perspektywie kryteriów jakościowych związanych z ich wdrożeniem i eksploatacją. Michalewicz (1999) podaje za (Baar i in., 1995) obszary analizy użyteczności nowej metody heurystycznej:

- tworzenie wysokiej jakości rozwiązań szybciej niż inne metody,
- wyznaczaniu rozwiązań o lepszej jakości niż inne metody,
- mniejszej wrażliwości na zmiany w cechach zadania, na jakość danych lub zmiany dostrajanych parametrów niż inne metody,
- łatwość użycia,
- możliwość zastosowania w szerszej klasie zadań.

Zaproponowane algorytmy pozwalają na uzyskanie wysokiej jakości rozwiązań, przy czym najbardziej atrakcyjny ze względu na ocenę uzyskanych rezultatów jest algorytm hybrydowy, który uzyskał najlepsze wyniki niezależnie od parametrów badanych problemów. Poza skutecznością w odnajdowaniu najlepszych

rozwiązań, algorytm hybrydowy charakteryzuje się największą stabilnością i najmniejszym wpływem doboru parametrów na uzyskiwany rezultat. Kolejne procedury o porównywalnej skuteczności to: algorytm genetyczny oraz symulowane wyżarzanie, które uzyskały wyniki o nieistotnych statystycznie różnicach i nieco mniejszej odporności na zmiany parametrów zadania oraz parametry samych procedur. Najslabszą procedurą w świetle przeprowadzonych badań jest algorytm poszukiwania z ruchami zabronionymi, który uzyskał najwyższy poziom błędu oraz znaczny spadek jakości rozwiązań przy wzroście złożoności obliczeniowej.

W ocenie podatności wdrożeniowej metaheurystyk głównym elementem jest ocena trudności skonstruowania i zaprogramowania odpowiednich procedur. Najtrudniejszym z punktu widzenia konstrukcyjnego jest algorytm hybrydowy, gdyż korzysta z największej liczby różnych technik, co przekłada się bezpośrednio na większą liczbę linii kodu i wiąże się z koniecznością opracowania, zakodowania, zwalidowania i zweryfikowania większej liczby procedur, czyli z większą pracochłonnością programistyczną. Z pozostałych metod najtrudniejszą konstrukcyjnie jest algorytm genetyczny, który posiada bardziej złożone mechanizmy poszukiwania rozwiązań od SA i TS. Jest charakterystyczna równica pomiędzy metodami operujących na populacji w porównaniu z metodami opartymi na jednym rozwiązaniu. Należy zaznaczyć, że znaczna część szczegółowych procedur jest wspólna dla wszystkich algorytmów, więc możliwe jest dyskontowanie zainwestowanego czasu w przypadku zmiany lub hybrydyzacji opracowanych uprzednio programów. Istotnym elementem stanowiącym największą barierę wdrożeniową dla przedstawianych metod jest poziom wiedzy i doświadczenia potrzebny dla efektywnego projektowania metaheurystyk.

Ostatnim elementem oceny użyteczności zastosowania badanych procedur w harmonogramowaniu projektów jest ocena trudności eksploatacyjnej, na którą składa się: poziom wiedzy i kompetencji wymagany dla obsługi operacyjnej algorytmów, pracochłonność związana z ich używaniem i utrzymaniem w sprawności technicznej oraz efektywność czasowa. Wszystkie projektowane procedury nie różnią się znacząco poziomem wiedzy, niezbędnej dla właściwego ich wykorzystania. Proste wytyczne w zakresie stosowanych parametrów pozwalają na uzyskanie wysokiej jakości rozwiązań. Największy poziom parametryzacji występuje w algorytmie hybrydowym, który dziedziczy parametry po procedurach, które wchodzi w jego skład, jednak z drugiej strony jest on najbardziej odporny na błędy obsługi w tym zakresie. Po wstępnym zestrojeniu procedur na etapie wdrażania, konieczność ponownego zbadania adekwatności parametrów może występować w przypadku radykalnej zmiany specyfiki prowadzonej działalności. Wprowadzenie mechanizmów samoadaptacyjnych i uczenia się pozwoliłoby na znaczne ograniczenie tego rodzaju zadań eksploatacyjnych. Pracochłonność związana z utrzymaniem sprawności technicznej programów jest największa w przypadku algorytmu hybrydowego, który jest najbardziej złożony od strony programistycznej, pozostałe procedury nie różnią się istotnie w tym aspekcie. Jednak niezależnie od wybranej metody poziom pracochłonności jest znikomy w przypadku stabilnego środowiska informatycznego dla zarządzania projektami w organizacji. Efektywność czasowa badanych procedur nie była szczegółowo badana z uwagi na wykorzystanie wielu różnych systemów komputerowych w trakcie eksperymentów i w efekcie brak możliwości ich porównania. Szacunkowe czasy przeprowadzenia eksperymentu na komputerze klasy PC (z procesorem taktowanym zegarem 3,0 GHz i dostępną pamięcią RAM 2GB) dla analizowanych problemów wahały się od kilku do kilkunastu minut, co jest wielkością w pełni satysfakcjonującą. Dodatkowo należy zauważyć możliwości optymalizacji kodu wynikające z usunięcia z przygotowanego programu wielu zbędnych w trakcie eksploatacji procedur diagnostycznych niezbędnych do pomiaru efektywności i analizy zachowania się badanych metod w trakcie eksperymentów.

Zestawione powyżej wnioski przemawiają za przydatnością stosowania metod wykorzystujących nowoczesne metaheurystyki we wspomaganiu procesów decyzyjnych związanych z zarządzaniem projektami w obszarze harmonogramowania w celu poprawy efektywności ekonomicznej.

Zakończenie i kierunki dalszych badań

Celem rozprawy było wskazanie korzyści płynących z harmonogramowania przebiegu przedsięwzięć (projektów) w oparciu o wybrane metaheurystyki z ukierunkowaniem na kryteria ekonomiczne poprzez analizę efektów ekonomicznych opracowanych procedur w wybranej grupie problemów. W pracy przedstawiono analizę problemów harmonogramowania przedsięwzięć ze szczególnym uwzględnieniem występujących ograniczeń i kryteriów oceny, następnie przedstawiono istniejące metody zarówno dokładne, jak i heurystyczne. Przeanalizowano dostępne kryteria oceny skuteczności harmonogramowania, zarówno techniczno-organizacyjne jak i ekonomiczne. Sformułowano model harmonogramowania projektu uwzględniającym możliwie precyzyjne opisanie parametrów ekonomicznych przedsięwzięcia i ich związku ze zmiennymi decyzyjnymi w procesie harmonogramowania. Następnie przedstawiono analizę technik stosowanych w dokładnych i heurystycznych metodach optymalizacji harmonogramów. Ostatnim etapem pracy badawczej było przeprowadzenie eksperymentów obliczeniowych pozwalających na ocenę zaproponowanych metod, analiza porównawcza skuteczności i potencjalnych trudności wdrożeniowych.

Na podstawie przeprowadzonych badań można sformułować następujące wnioski:

- Wykorzystanie metaheurystyk pozwala na efektywne i skuteczne rozwiązywanie problemów harmonogramowania projektów w oparciu o kryteria ekonomiczne. Metaheurystyki mogą stanowić atrakcyjne narzędzie do wspomagania procesu podejmowania decyzji umożliwiając racjonalny wybór jednej z wielu możliwości działania.
- Proste metody heurystyczne nie pozwalają na elastyczne modelowanie harmonogramów przedsięwzięć. Wdrożenie metod heurystycznych (szczególnie priorytetowych) wiąże się z koniecznością dokonania wielu uproszczeń przez co skutki ekonomiczne wdrożenia uzyskanych za ich pomocą harmonogramów mogą znacznie odbiegać od rozwiązań zadowalających.
- Wadą metaheurystyk w porównaniu z heurystykami priorytetowymi jest konieczność strojenia parametrów i doboru stosowanych w nich technik, przez co dla uzyskania satysfakcjonującego efektu konieczne jest każdorazowe przeprowadzenie dodatkowych badań pozwalających uwzględnić specyfikę danej organizacji.
- Sformułowany w pracy model harmonogramowania z uwagi na uwzględnienie szerokich i zróżnicowanych możliwości modelowania przedsięwzięcia (dostępnych w powszechnie stosowanym oprogramowaniu do wspomagania zarządzania projektami) pozwala na szerokie zastosowanie praktyczne przedstawionych i przebadanych metod w zarządzaniu przedsięwzięciami.
- Spośród prostych (homogenicznych) metaheurystyk algorytm genetyczny oraz algorytm symulowanego wyżarzania pozwalają na uzyskanie istotnie lepszych harmonogramów ze względu na przyjęte dynamiczne kryteria ekonomiczne niezależnie od parametrów problemu.
- Zaproponowany algorytm hybrydowy pozwolił na uzyskanie lepszych harmonogramów ze względu na przyjęte dynamiczne kryteria oceny ekonomicznej niezależnie od wielkości i innych parametrów problemu.

- Zaproponowany algorytm hybrydowy charakteryzuje się największą stabilnością uzyskiwanych wyników dla badanych problemów. Ponadto w przypadku algorytmu hybrydowego najmniej istotny jest wpływ parametrów na skuteczność procesu poszukiwania rozwiązania. Cechy te sprawiają, że pomimo skomplikowania konstrukcyjnego, sprawia najmniej problemów w okresie eksploatacji. Algorytmy homogeniczne z uwagi na prostszą konstrukcję (nie wymagającą wysokich kompetencji) i mniejszy stopień parametryzacji mogą stanowić atrakcyjną alternatywę dla rozwiązań hybrydowych pomimo nieznacznie mniejszej skuteczności.
- Najsilniejszy i najistotniejszy wpływ na trudność rozwiązania problemu przez badane metody mają: liczba czynności do uszeregowania, poziom ścisłości ograniczeń zasobów odnawialnych, poziom ścisłości ograniczeń zasobów nieodnawialnych. Nie stwierdzono istotnego wpływu liczby ograniczeń kolejnościowych na trudność rozwiązania problemu w badanej grupie problemów. Wraz ze wzrostem liczby czynności do umieszczenia w harmonogramie projektu wzrasta poziom trudności zbudowania harmonogramu.
- Optymalizacja charakterystyk czasowych przedsięwzięcia, nie jest jednoznaczna z optymalizacją kryteriów ekonomicznych. Stosowanie kryteriów techniczno-organizacyjnych może wiązać się ze spadkiem wartości kryteriów ekonomicznych (w szczególności dynamicznych) przez co może prowadzić do podejmowania decyzji niezgodnych z zasadą racjonalnego działania przedsiębiorstwa powodując osiągnięcie celów przy nieuzasadnionym wzroście kosztów.

Na podstawie przedstawionych wniosków można uznać, że **teza rozprawy została udowodniona**.

Kierunki dalszych badań związanych ze stosowaniem nowoczesnych metaheurystyk w optymalizacji harmonogramowania przedsięwzięć mogą być następujące:

- Wprowadzenie mechanizmów adaptacji parametrów w przygotowanych procedurach dla ograniczenia koniecznych badań na etapie wdrożenia i większej stabilności w zakresie skuteczności działania.
- Wprowadzenie mechanizmów pamięci i uczenia się dla doboru właściwych metod, technik i parametrów w zależności od parametrów rozwiązywanych problemów dla uniezależnienia jakości i stabilności uzyskiwanych rozwiązań od szerokiej parametryzacji problemów oraz potencjalnie umożliwienie wykorzystania efektów uczenia (np. zbioru reguł) do ograniczenia wstępnej parametryzacji.
- Analiza możliwości zastosowania pozostałych metaheurystyk (w tym poszukiwania rozproszonego, algorytmów kolonii mrówek i algorytmu uczenia populacji) w rozwiązaniu przedstawionych problemów w ramach skonstruowanego modelu oraz analiza możliwości i zakresu ich wykorzystania w metodach hybrydowych.
- Opracowanie wielokryterialnych metod harmonogramowania projektów z wykorzystaniem metaheurystyk na podstawie technik opisanych w rozprawie. W świetle wyników badań wydaje się, że optymalizacja wielokryterialna zastępująca ograniczenia w modelu kryteriami oceny, stanowi bardziej atrakcyjną alternatywę dla procedur jednokryterialnych. W efekcie istnieje możliwość uzyskania zestawu wysokiej jakości rozwiązań (np. optymalnych w sensie Pareto), które mogą być przeanalizowane przez menedżera w celu podjęcia decyzji uwzględniającej również dodatkowe czynniki wyłączone z modelu.
- Analiza możliwości wdrożenia metod w innych problemach harmonogramowania (w tym w problemach harmonogramowania wielu projektów). Ten kierunek badań wydaje się również bardzo atrakcyjny z uwagi na rosnącą popularność zarządzania przez projekty i organizacji działających w warunkach realizacji wielu projektów jednocześnie.
- Opracowanie wytycznych dla procesu wdrożenia innowacji technologicznej polegającej na zastosowaniu wybranych metod w organizacjach zarządzanych przez projekty. Rozwinięcie tego kierunku badań wraz z integracją opracowanych metod z dostępnym i stosowanym oprogramowaniem wspomagającym zarządzanie projektami powinno pozwolić na skuteczne wdrożenie wyników przeprowadzonych badań w organizacjach zarządzanych przez projekty.

Standaryzacja relacji

Ogólny model relacji pozwala stosować dla opisu zależności pomiędzy czynnościami czterech rodzajów relacji. Bartusch, Möhring i Radermacher (1988) przedstawiają metodę konwersji ogólnego modelu do formy standardowej z jednym rodzajem relacji poprzez dookreślenie względnych ograniczeń czasowych. Ogólny model relacji przyjmuje postać:

$$S_i^\omega + \mathbb{RR}_{i \rightarrow j}^{\min} \leq S_j^\omega \leq S_i^\omega + \mathbb{RR}_{i \rightarrow j}^{\max} \quad (\text{A.1})$$

$$S_i^\omega + \mathbb{RZ}_{i \rightarrow j}^{\min} \leq \mathcal{F}_j^\omega \leq S_i^\omega + \mathbb{RZ}_{i \rightarrow j}^{\max} \quad (\text{A.2})$$

$$\mathcal{F}_i^\omega + \mathbb{ZR}_{i \rightarrow j}^{\min} \leq S_j^\omega \leq \mathcal{F}_i^\omega + \mathbb{ZR}_{i \rightarrow j}^{\max} \quad (\text{A.3})$$

$$\mathcal{F}_i^\omega + \mathbb{ZZ}_{i \rightarrow j}^{\min} \leq \mathcal{F}_j^\omega \leq \mathcal{F}_i^\omega + \mathbb{ZZ}_{i \rightarrow j}^{\max} \quad (\text{A.4})$$

Dla tak określonego modelu relacji standaryzacja do relacji typu $\mathbb{RR}$ oparta jest o reguły¹:

$$S_i^\omega + \mathbb{RR}_{i \rightarrow j}^{\min} \leq S_j^\omega \implies S_i^\omega + L_{i \rightarrow j} \leq S_j^\omega \quad | \quad L_{i \rightarrow j} = \mathbb{RR}_{i \rightarrow j}^{\min} \quad (\text{A.5})$$

$$S_i^\omega + \mathbb{RR}_{i \rightarrow j}^{\max} \geq S_j^\omega \implies S_j^\omega + L_{j \rightarrow i} \leq S_i^\omega \quad | \quad L_{j \rightarrow i} = -\mathbb{RR}_{i \rightarrow j}^{\max} \quad (\text{A.6})$$

$$S_i^\omega + \mathbb{RZ}_{i \rightarrow j}^{\min} \leq \mathcal{F}_j^\omega \implies S_i^\omega + L_{i \rightarrow j} \leq S_j^\omega \quad | \quad L_{i \rightarrow j} = \mathbb{RZ}_{i \rightarrow j}^{\min} - T_j \quad (\text{A.7})$$

$$S_i^\omega + \mathbb{RZ}_{i \rightarrow j}^{\max} \geq \mathcal{F}_j^\omega \implies S_j^\omega + L_{j \rightarrow i} \leq S_i^\omega \quad | \quad L_{j \rightarrow i} = T_j - \mathbb{RZ}_{i \rightarrow j}^{\max} \quad (\text{A.8})$$

$$\mathcal{F}_i^\omega + \mathbb{ZR}_{i \rightarrow j}^{\min} \leq S_j^\omega \implies S_i^\omega + L_{i \rightarrow j} \leq S_j^\omega \quad | \quad L_{i \rightarrow j} = T_i + \mathbb{ZR}_{i \rightarrow j}^{\min} \quad (\text{A.9})$$

$$\mathcal{F}_i^\omega + \mathbb{ZR}_{i \rightarrow j}^{\max} \geq S_j^\omega \implies S_j^\omega + L_{j \rightarrow i} \leq S_i^\omega \quad | \quad L_{j \rightarrow i} = \mathbb{ZR}_{i \rightarrow j}^{\max} - T_i \quad (\text{A.10})$$

$$\mathcal{F}_i^\omega + \mathbb{ZZ}_{i \rightarrow j}^{\min} \leq \mathcal{F}_j^\omega \implies S_i^\omega + L_{i \rightarrow j} \leq S_j^\omega \quad | \quad L_{i \rightarrow j} = T_i - T_j + \mathbb{ZZ}_{i \rightarrow j}^{\min} \quad (\text{A.11})$$

$$\mathcal{F}_i^\omega + \mathbb{ZZ}_{i \rightarrow j}^{\max} \geq \mathcal{F}_j^\omega \implies S_j^\omega + L_{j \rightarrow i} \leq S_i^\omega \quad | \quad L_{j \rightarrow i} = T_j - T_i + \mathbb{ZZ}_{i \rightarrow j}^{\max} \quad (\text{A.12})$$

¹Dla uproszczenia zapisu przyjęto czas wykonania czynności oznaczać jako T_i , pomijając kwestię sposobu wykonania.

Opis formatu pso

Dla zapisu instancji problemów klasy RCPS zgodnie z opsiem sformułowanym w p. 4.1 niniejszej pracy przygotowano dedykowaną strukturę pliku tekstowego. Plik składa się z elementów obligatoryjnych zawierających dane modelu oraz opcjonalnych elementów poprawiających czytelność zapisu. Każdy z elementów obligatoryjnych zawarty jest w jednej linii pliku. Jako separator danych zastosowano przecinek (separatorem dziesiętnym jest kropka). Każda z linii danych rozpoczyna się od identyfikatora wskazującego na rodzaj elementu obligatoryjnego zgodnie z tabelą B.1. Poniżej przedstawiono strukturę każdego elementu oraz sposób odczytywania danych poszczególnych składników modelu na podstawie ich zapisu w formacie pso. Struktura danych w linii określona jest następująco:

- dla i -tego projektu
 $p, i, S_{\pi i}^{\min}, \mathcal{D}_i^{\pi}, \mathcal{E}\mathcal{L}_i^{\pi}, \mathcal{E}\mathcal{f}\mathcal{S}_i^{\pi}, \mathcal{E}\mathcal{f}\mathcal{P}_i^{\pi}, \mathcal{E}\mathcal{f}\mathcal{F}_i^{\pi}$
- dla r -tego zasobu odnawialnego
 $rr, r, \mathcal{E}\mathcal{f}\mathcal{S}_r^{\rho}, \mathcal{E}\mathcal{f}\mathcal{P}_r^{\rho}, \mathcal{E}\mathcal{f}\mathcal{F}_r^{\rho}, \mathcal{E}\mathcal{v}\mathcal{S}_r^{\rho}, \mathcal{E}\mathcal{v}\mathcal{P}_r^{\rho}, \mathcal{E}\mathcal{v}\mathcal{F}_r^{\rho},$
 $\hookrightarrow \quad, \{0, t_1, \rho[r, 0, \dots, t_1, C]\}, \dots, \{t_i, t_{i+1}, \rho[r, t_i, \dots, t_{i+1}, C]\},$
- dla r -tego zasobu nieodnawialnego
 $nr, r, \mathcal{E}\mathcal{f}\mathcal{S}_r^{\nu}, \mathcal{E}\mathcal{f}\mathcal{P}_r^{\nu}, \mathcal{E}\mathcal{f}\mathcal{F}_r^{\nu}, \mathcal{E}\mathcal{v}\mathcal{S}_r^{\nu}, \mathcal{E}\mathcal{v}\mathcal{P}_r^{\nu}, \mathcal{E}\mathcal{v}\mathcal{F}_r^{\nu}, C_r^{\nu},$
- dla i -tej czynności czynności
 $a, i, \omega_i^{\pi}, \mathcal{I}_i^{\omega}, S_i^{\min}, S_i^{\max}, \tilde{\mathcal{M}}_i^{\omega},$
 $\hookrightarrow \quad, \{j, \mathcal{L}_{i \rightarrow j}^{\max}, \mathcal{L}_{i \rightarrow j}^{\min}\}, \dots, \{k, \mathcal{L}_{i \rightarrow k}^{\max}, \mathcal{L}_{i \rightarrow k}^{\min}\},$
- dla m -tego sposobu wykonania i -tej czynności
 $m, i, m, \omega[i, m, \mathcal{T}], \omega[i, m, \mathcal{E}\mathcal{f}\mathcal{S}], \omega[i, m, \mathcal{E}\mathcal{f}\mathcal{P}], \omega[i, m, \mathcal{E}\mathcal{f}\mathcal{F}],$
 $\hookrightarrow \quad, [\omega[i, m, \rho_0], \omega[i, m, \rho_1], \dots, \omega[i, m, \rho_n],], [\omega[i, m, \nu_0], \omega[i, m, \nu_1], \dots, \omega[i, m, \nu_r],],$

Symbol	Znaczenie
p	oznaczenie linii projektu
rr	oznaczenie linii zasobu odnawialny
nr	oznaczenie linii zasobu nieodnawialny
a	oznaczenie linii czynności
m	oznaczenie linii sposobu wykonania czynności

Tab. B.1: Identyfikatory elementów danych w formacie pso

Przykładowa linia definiująca dane 1-szego **projektu**:

$$p, 1, 10, 231.5, 3.1, 85.45, 16.32, 26.17$$

czyli:

$$\begin{aligned} S_{\pi 1}^{\min} &= 10 & Ef S_1^{\pi} &= 85,45 \\ D_1^{\pi} &= 231,5 & Ef P_1^{\pi} &= 16,32 \\ \mathcal{E}L_1^{\pi} &= 3,1 & Ef F_1^{\pi} &= 26,17 \end{aligned}$$

Przykładowa linia definiująca dane 2-giego **zasobu odnawialnego**:

$$rr, 2, 0.00, 2.44, 0.00, 0.00, 1.47, 5.25, \{, 0, 21, 0, \}, \{, 22, 325, 35, \}, \{, 326, 2147483647, 25, \}$$

czyli:

$$\rho[2, t, C] = \begin{cases} 0 & \text{dla } t \in \langle 0; 21 \rangle \\ 35 & \text{dla } t \in \langle 22; 325 \rangle \\ 25 & \text{dla } t \in \langle 326; 2147483647 \rangle \end{cases}$$

$$\begin{aligned} Ef S_2^{\rho} &= 0 & \mathcal{E}v S_2^{\rho} &= 0 \\ Ef P_2^{\rho} &= 2,44 & \mathcal{E}v P_2^{\rho} &= 1,47 \\ Ef F_2^{\rho} &= 0 & \mathcal{E}v F_2^{\rho} &= 5,25 \end{aligned}$$

Przykładowa linia definiująca dane 6-tego **zasobu nieodnawialnego**:

$$nr, 6, 0.00, 4.26, 0.00, 17.36, 0.00, 11.26, 212$$

czyli:

$$\begin{aligned} C_6^{\nu} &= 212 & Ef S_6^{\nu} &= 0 \\ \mathcal{E}v S_6^{\nu} &= 17,36 & Ef P_6^{\nu} &= 4,26 \\ \mathcal{E}v P_6^{\nu} &= 0 & Ef F_6^{\nu} &= 0 \\ \mathcal{E}v F_6^{\nu} &= 11,26 \end{aligned}$$

Przykładowa linia definiująca dane 5-tej **czynności**:

$$a, 5, 1, 234.43, 12, 172, 2, \{, 22, -11, 215, \}, \{, 37, 12, 73, \}$$

czyli:

$$\begin{aligned} \omega_5^{\pi} &= 1 & ZR_{5 \rightarrow 22}^{\min} &= -11 \\ I_5^{\omega} &= 234,43 & ZR_{5 \rightarrow 22}^{\max} &= 215 \\ S_5^{\min} &= 12 & ZR_{5 \rightarrow 37}^{\min} &= 12 \\ S_5^{\max} &= 172 & ZR_{5 \rightarrow 37}^{\max} &= 73 \\ M_5^{\omega} &= 2 \end{aligned}$$

Przykładowa linia definiująca dane 1-szego **sposobu wykonania** 5-tej czynności:

$$m, 5, 1, 10, 15.76, 0.00, 0.00, [, 0, 0, 12, 9, 0], [, 0, 3, 27,]$$

czyli:

$$\begin{aligned} \omega[5, 1, \mathcal{T}] &= 10 \\ \omega[5, 1, Ef S] &= 15,76 \\ \omega[5, 1, Ef P] &= 0,00 \\ \omega[5, 1, Ef F] &= 0,00 \\ \omega[5, 1, \rho_1] &= 0 & \omega[5, 1, \nu_1] &= 0 \\ \omega[5, 1, \rho_2] &= 0 & \omega[5, 1, \nu_2] &= 3 \\ \omega[5, 1, \rho_3] &= 12 & \omega[5, 1, \nu_3] &= 27 \\ \omega[5, 1, \rho_4] &= 9 \\ \omega[5, 1, \rho_5] &= 0 \end{aligned}$$

Statystyki opisowe wyników badań eksperymentalnych

Poniżej przedstawiono podsumowanie wyników uzyskanych w badaniu wybranych metod w zbiorze 270 modeli harmonogramowania projektów. W tabelach zastosowano następujące oznaczenia:

Symbol	Znaczenie
n	liczebność próby
$\bar{x}$	średnia arytmetyczna wartości $\bar{\epsilon}$ z próby
s	odchylenie standardowe wartości $\bar{\epsilon}$ z próby
s_E	błąd standardowy wartości $\bar{\epsilon}$ z próby
-95	dolne oszacowanie 95-procentowego przedziału ufności wartości $\bar{\epsilon}$
+95	górne oszacowanie 95-procentowego przedziału ufności wartości $\bar{\epsilon}$
Min	najmniejsza wartość $\bar{\epsilon}$ z próby
Q25	dolny kwartył wartości $\bar{\epsilon}$ z próby
Q50	mediana wartości $\bar{\epsilon}$ z próby
Q75	górny kwartył wartości $\bar{\epsilon}$ z próby
Max	największa wartość $\bar{\epsilon}$ z próby

Tab. C.1: Statystyki opisowe wyników algorytmu SA dla $\tilde{\Omega} = 30$

#	$\tilde{S}^A$	β	p_p	p_m	C	S	N	$\Delta_{\max}$	h	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
1	20 000	BM	0,90	0,02	4	5	494	0,1	0	270	0,41	0,45	0,03	-0,46	1,29	0,00	0,09	0,29	0,58	3,02
2	20 000	BM	0,90	0,02	4	5	494	0,5	0	270	0,42	0,47	0,03	-0,51	1,35	0,00	0,09	0,29	0,55	2,74
3	20 000	BM	0,90	0,02	5	5	396	0,2	0	270	0,42	0,43	0,03	-0,43	1,27	0,00	0,09	0,29	0,60	2,48
4	20 000	BM	0,90	0,02	5	5	396	0,5	0	270	0,43	0,54	0,03	-0,64	1,49	0,00	0,09	0,27	0,62	5,47
5	20 000	BM	0,90	0,02	7	5	283	0,5	0	270	0,43	0,46	0,03	-0,47	1,34	0,00	0,10	0,29	0,61	3,07
6	20 000	BM	0,90	0,02	6	5	330	0,2	0	270	0,44	0,42	0,03	-0,38	1,26	0,00	0,12	0,34	0,61	2,34
7	20 000	BM	0,90	0,02	2	5	989	0,2	0	270	0,44	0,61	0,04	-0,76	1,65	0,00	0,05	0,27	0,60	5,54
8	20 000	BM	0,90	0,02	3	5	659	0,2	0	270	0,45	0,63	0,04	-0,78	1,67	0,00	0,06	0,23	0,57	5,43
9	20 000	BM	0,90	0,02	3	5	659	0,5	0	270	0,46	0,55	0,03	-0,61	1,53	0,00	0,07	0,28	0,62	3,00
10	20 000	BM	0,90	0,02	3	5	659	0,1	0	270	0,46	0,49	0,03	-0,51	1,43	0,00	0,09	0,33	0,66	3,57
11	20 000	BM	0,90	0,02	4	5	494	0,2	0	270	0,47	0,56	0,03	-0,62	1,57	0,00	0,09	0,28	0,68	3,52
12	20 000	BM	0,90	0,02	2	5	989	0,5	0	270	0,49	0,67	0,04	-0,82	1,80	0,00	0,06	0,25	0,67	5,47
13	20 000	BM	0,90	0,02	6	5	330	0,1	0	270	0,49	0,52	0,03	-0,54	1,52	0,00	0,12	0,33	0,64	3,25
14	20 000	BM	0,90	0,02	6	5	330	0,5	0	270	0,49	0,78	0,05	-1,03	2,01	0,00	0,14	0,32	0,70	11,10
15	20 000	BM	0,90	0,02	7	5	283	0,2	0	270	0,50	0,50	0,03	-0,49	1,48	0,00	0,16	0,34	0,66	3,08
16	20 000	BM	0,90	0,02	8	5	248	0,2	0	270	0,51	0,47	0,03	-0,41	1,44	0,00	0,16	0,38	0,72	2,66
17	20 000	BM	0,90	0,02	2	5	989	0,1	0	270	0,53	0,71	0,04	-0,86	1,92	0,00	0,07	0,31	0,75	6,16
18	20 000	BM	0,90	0,02	9	5	220	0,5	0	270	0,53	0,45	0,03	-0,34	1,41	0,00	0,20	0,43	0,77	3,18
19	20 000	BM	0,90	0,02	5	5	396	0,1	0	270	0,54	0,56	0,03	-0,57	1,64	0,00	0,14	0,39	0,74	3,39
20	20 000	BM	0,90	0,02	8	5	248	0,5	0	270	0,55	0,52	0,03	-0,48	1,57	0,00	0,17	0,39	0,75	3,02
21	20 000	BM	0,90	0,02	8	5	248	0,1	0	270	0,55	0,55	0,03	-0,52	1,62	0,00	0,14	0,39	0,81	3,04
22	20 000	BM	0,90	0,02	10	5	199	0,2	0	270	0,55	0,46	0,03	-0,36	1,46	0,00	0,19	0,45	0,80	2,53
23	20 000	BM	0,90	0,02	7	5	283	0,1	0	270	0,55	0,53	0,03	-0,48	1,59	0,00	0,15	0,41	0,80	2,48
24	20 000	BM	0,90	0,02	9	5	220	0,2	0	270	0,56	0,52	0,03	-0,47	1,58	0,00	0,18	0,41	0,78	3,00
25	20 000	BM	0,90	0,02	10	5	199	0,1	0	270	0,56	0,48	0,03	-0,39	1,50	0,00	0,18	0,45	0,79	3,15
26	20 000	BM	0,90	0,02	10	5	199	0,5	0	270	0,57	0,49	0,03	-0,39	1,54	0,00	0,21	0,46	0,76	2,52
27	20 000	BM	0,90	0,02	9	5	220	0,1	0	270	0,58	0,57	0,03	-0,54	1,70	0,00	0,15	0,42	0,85	3,23
28	20 000	BM	0,90	0,02	1	5	1973	0,2	0	270	0,60	0,79	0,05	-0,94	2,15	0,00	0,11	0,34	0,71	5,67
29	20 000	BM	0,90	0,02	1	5	1973	0,5	0	270	0,64	1,54	0,09	-2,37	3,65	0,00	0,06	0,31	0,72	21,03
30	20 000	BM	0,90	0,02	1	5	1973	0,1	0	270	0,64	0,85	0,05	-1,02	2,31	0,00	0,07	0,33	0,84	5,49
31	20 000	BM	0,90	0,02	9	10	18	0,2	0	270	0,68	0,63	0,04	-0,55	1,91	0,00	0,24	0,49	0,93	3,72
32	20 000	BM	0,90	0,02	10	10	16	0,2	0	270	0,69	0,61	0,04	-0,51	1,88	0,00	0,21	0,57	0,95	3,44

Tab. C.1: Statystyki opisowe wyników algorytmu $\mathbb{S}\mathbb{A}$ dla $\hat{\Omega} = 30$ (c.d.)

#	$\mathbb{S}\mathbb{A}$	β	p_p	p_m	C	S	N	$\Delta_{\max}$	h	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	$-95[\%]$	$+95[\%]$	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
33	20 000	BM	0,90	0,02	7	10	21	0,2	0	270	0,73	0,67	0,04	-0,59	2,05	0,00	0,26	0,54	1,05	4,96
34	20 000	BM	0,90	0,02	8	10	19	0,2	0	270	0,74	0,65	0,04	-0,54	2,03	0,00	0,31	0,57	1,04	3,54
35	20 000	BM	0,90	0,02	6	10	25	0,2	0	270	0,78	0,77	0,05	-0,73	2,29	0,00	0,26	0,59	1,04	4,09
36	20 000	BM	0,90	0,02	5	15	2	0,2	0	270	0,80	0,79	0,05	-0,74	2,34	0,00	0,21	0,55	1,18	5,61
37	20 000	BM	0,70	0,02	5	10	30	0,2	0	270	0,84	0,74	0,04	-0,61	2,29	0,00	0,32	0,66	1,17	5,64
38	20 000	BM	0,90	0,02	4	10	37	0,2	0	270	0,86	0,78	0,05	-0,66	2,39	0,00	0,32	0,70	1,11	4,05
39	20 000	BM	0,90	0,02	5	10	30	0,2	0	270	0,87	0,84	0,05	-0,77	2,51	0,00	0,28	0,63	1,22	4,80
40	20 000	BM	0,90	0,04	5	10	30	0,2	0	270	0,87	0,86	0,05	-0,81	2,55	0,00	0,23	0,60	1,29	4,94
41	20 000	BM	0,90	0,01	5	10	30	0,2	0	270	0,87	0,79	0,05	-0,68	2,42	0,00	0,30	0,64	1,25	4,35
42	20 000	BM	0,70	0,01	5	10	30	0,2	0	270	0,90	0,88	0,05	-0,82	2,63	0,00	0,29	0,61	1,28	4,86
43	20 000	BM	0,90	0,06	5	10	30	0,2	0	270	0,92	0,80	0,05	-0,65	2,50	0,00	0,33	0,69	1,34	4,03
44	20 000	BM	0,50	0,02	5	10	30	0,2	0	270	0,95	1,02	0,06	-1,04	2,95	0,00	0,31	0,71	1,27	11,04
45	20 000	BM	0,70	0,04	5	10	30	0,2	0	270	0,97	0,87	0,05	-0,73	2,68	0,00	0,35	0,74	1,33	5,75
46	20 000	BM	0,50	0,01	5	10	30	0,2	0	270	0,99	0,83	0,05	-0,64	2,63	0,00	0,35	0,81	1,38	4,50
47	20 000	BM	0,90	0,02	3	10	48	0,2	0	270	1,02	0,93	0,06	-0,81	2,85	0,00	0,33	0,79	1,49	5,08
48	20 000	BM	0,70	0,06	5	10	30	0,2	0	270	1,08	0,85	0,05	-0,58	2,73	0,00	0,45	0,92	1,53	4,80
49	20 000	BM	0,90	0,08	5	10	30	0,2	0	270	1,11	0,94	0,06	-0,73	2,95	0,00	0,42	0,90	1,47	5,56
50	20 000	BM	0,50	0,04	5	10	30	0,2	0	270	1,13	0,94	0,06	-0,71	2,98	0,00	0,39	0,89	1,55	4,38
51	20 000	BM	0,90	0,02	2	3	2419	0,2	0	270	1,18	0,56	0,03	0,09	2,27	0,26	0,79	1,09	1,48	3,75
52	20 000	BM	0,70	0,08	5	10	30	0,2	0	270	1,18	0,93	0,06	-0,63	3,00	0,00	0,54	0,97	1,53	6,81
53	20 000	MM	0,90	0,02	2	5	989	0,2	0	270	1,21	1,30	0,08	-1,34	3,75	0,00	0,30	0,80	1,75	8,10
54	20 000	BM	0,30	0,01	5	10	30	0,2	0	270	1,21	1,01	0,06	-0,77	3,19	0,00	0,52	0,99	1,62	6,65
55	20 000	HM	0,90	0,02	2	5	989	0,2	0	270	1,22	1,43	0,09	-1,58	4,01	0,00	0,31	0,73	1,63	10,26
56	20 000	BM	0,90	0,02	3	3	1613	0,2	0	270	1,23	0,64	0,04	-0,03	2,49	0,19	0,86	1,14	1,51	6,64
57	20 000	HM	0,90	0,02	3	5	659	0,2	0	270	1,23	1,29	0,08	-1,30	3,77	0,00	0,29	0,78	1,82	7,13
58	20 000	BM	0,90	0,02	4	3	1210	0,2	0	270	1,24	0,51	0,03	0,23	2,25	0,22	0,88	1,17	1,54	3,02
59	20 000	MM	0,90	0,02	3	5	659	0,2	0	270	1,25	1,32	0,08	-1,34	3,84	0,00	0,29	0,78	1,76	7,17
60	20 000	BM	0,50	0,06	5	10	30	0,2	0	270	1,26	0,99	0,06	-0,69	3,20	0,00	0,56	1,02	1,72	5,34
61	20 000	BM	0,30	0,02	5	10	30	0,2	0	270	1,26	0,95	0,06	-0,61	3,12	0,00	0,57	1,00	1,66	4,51
62	20 000	BM	0,90	0,02	1	3	4837	0,2	0	270	1,26	0,72	0,04	-0,16	2,67	0,01	0,78	1,13	1,55	6,63
63	20 000	BM	0,90	0,10	5	10	30	0,2	0	270	1,27	1,01	0,06	-0,70	3,25	0,00	0,55	1,07	1,74	8,07
64	20 000	BM	0,90	0,02	6	3	807	0,2	0	270	1,28	0,52	0,03	0,26	2,29	0,12	0,90	1,25	1,60	3,21

Tab. C.1: Statystyki opisowe wyników algorytmu SA dla $\tilde{\Omega} = 30$ (c.d.)

#	$\tilde{S}^A$	β	p_p	p_m	C	S	N	$\Delta_{\max}$	h	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	$-95[\%]$	$+95[\%]$	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
65	20 000	BM	0,90	0,02	2	10	71	0,2	0	270	1,28	1,26	0,08	-1,20	3,76	0,00	0,42	0,84	1,69	7,45
66	20 000	BM	0,90	0,02	2	15	3	0,2	0	270	1,28	1,33	0,08	-1,32	3,88	0,00	0,32	0,96	1,86	11,04
67	20 000	BM	0,90	0,02	5	3	969	0,2	0	270	1,31	0,52	0,03	0,28	2,33	0,20	0,90	1,25	1,62	2,65
68	20 000	MM	0,90	0,02	4	5	494	0,2	0	270	1,32	1,38	0,08	-1,38	4,02	0,00	0,36	0,87	1,85	10,62
69	20 000	MM	0,90	0,02	5	5	396	0,2	0	270	1,36	1,30	0,08	-1,20	3,91	0,00	0,44	0,91	1,78	6,01
70	20 000	BM	0,90	0,02	8	3	605	0,2	0	270	1,36	0,54	0,03	0,30	2,42	0,20	1,00	1,31	1,64	3,20
71	20 000	BM	0,90	0,02	7	3	692	0,2	0	270	1,40	0,56	0,03	0,30	2,49	0,14	1,00	1,39	1,74	4,19
72	20 000	MM	0,90	0,02	6	5	330	0,2	0	270	1,40	1,40	0,09	-1,35	4,15	0,00	0,42	0,90	2,06	8,72
73	20 000	HM	0,90	0,02	4	5	494	0,2	0	270	1,41	1,65	0,10	-1,83	4,65	0,00	0,41	0,89	1,75	12,04
74	20 000	HM	0,90	0,02	5	5	396	0,2	0	270	1,43	1,54	0,09	-1,60	4,46	0,00	0,46	0,97	1,86	11,33
75	20 000	BM	0,90	0,02	10	3	485	0,2	0	270	1,45	0,56	0,03	0,35	2,56	0,29	1,08	1,37	1,81	3,50
76	20 000	BM	0,90	0,02	9	3	539	0,2	0	270	1,45	0,59	0,04	0,30	2,61	0,24	1,04	1,40	1,76	3,42
77	20 000	HM	0,90	0,02	8	5	248	0,2	0	270	1,47	1,23	0,07	-0,94	3,87	0,00	0,59	1,12	2,03	7,17
78	20 000	BM	0,30	0,04	5	10	30	0,2	0	270	1,47	1,11	0,07	-0,72	3,65	0,00	0,65	1,20	1,98	6,15
79	20 000	BM	0,90	0,02	1	10	141	0,2	0	270	1,47	1,49	0,09	-1,44	4,39	0,00	0,42	1,05	2,05	8,09
80	20 000	MM	0,90	0,02	1	5	1973	0,2	0	270	1,48	1,83	0,11	-2,10	5,06	0,00	0,26	0,83	2,01	11,96
81	20 000	MM	0,90	0,02	7	5	283	0,2	0	270	1,48	1,53	0,09	-1,51	4,48	0,00	0,54	1,00	1,95	14,59
82	20 000	HM	0,90	0,02	6	5	330	0,2	0	270	1,49	1,60	0,10	-1,65	4,62	0,00	0,50	1,06	2,00	16,89
83	20 000	HM	0,90	0,02	7	5	283	0,2	0	270	1,50	1,43	0,09	-1,31	4,32	0,00	0,50	1,08	2,03	10,58
84	20 000	MM	0,90	0,02	8	5	248	0,2	0	270	1,53	1,39	0,08	-1,20	4,26	0,00	0,62	1,13	2,08	10,63
85	20 000	HM	0,90	0,02	1	5	1973	0,2	0	270	1,55	1,74	0,11	-1,87	4,97	0,00	0,31	0,96	2,15	10,89
86	20 000	BM	0,50	0,08	5	10	30	0,2	0	270	1,56	1,00	0,06	-0,41	3,52	0,00	0,82	1,32	2,05	5,15
87	20 000	BM	0,70	0,10	5	10	30	0,2	0	270	1,56	1,11	0,07	-0,62	3,73	0,07	0,71	1,28	2,18	5,63
88	20 000	HM	0,90	0,02	9	5	220	0,2	0	270	1,59	1,44	0,09	-1,23	4,42	0,00	0,55	1,17	2,16	10,93
89	20 000	HM	0,90	0,02	10	5	199	0,2	0	270	1,61	1,46	0,09	-1,25	4,47	0,05	0,69	1,18	1,95	12,82
90	20 000	MM	0,90	0,02	9	5	220	0,2	0	270	1,61	1,41	0,09	-1,15	4,38	0,00	0,59	1,22	2,16	10,52
91	20 000	MM	0,90	0,02	10	5	199	0,2	0	270	1,70	1,47	0,09	-1,19	4,58	0,00	0,65	1,22	2,24	11,10
92	20 000	BM	0,30	0,06	5	10	30	0,2	0	270	1,70	1,11	0,07	-0,48	3,87	0,12	0,86	1,41	2,31	5,56
93	20 000	BM	0,90	0,02	1	15	5	0,2	0	270	1,90	2,06	0,13	-2,14	5,93	0,00	0,50	1,17	2,73	12,27
94	20 000	BM	0,50	0,10	5	10	30	0,2	0	270	1,90	1,29	0,08	-0,62	4,42	0,11	0,96	1,61	2,55	6,77
95	20 000	BM	0,30	0,08	5	10	30	0,2	0	270	2,25	1,28	0,08	-0,27	4,76	0,19	1,29	1,99	3,07	6,34
96	20 000	BM	0,10	0,01	5	10	30	0,2	0	270	2,25	1,42	0,09	-0,53	5,03	0,04	1,22	1,95	2,97	8,01

Tab. C.1: Statystyki opisowe wyników algorytmu $\mathcal{S}\mathcal{A}$ dla $\hat{\Omega} = 30$ (c.d.)

#	$\mathcal{S}\mathcal{A}$	β	p_p	p_m	C	S	N	$\Delta_{\max}$	h	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	$-95[\%]$	$+95[\%]$	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
97	20 000	BM	0,10	0,02	5	10	30	0,2	0	270	2,51	1,39	0,08	-0,20	5,23	0,12	1,37	2,29	3,32	7,93
98	20 000	BM	0,30	0,10	5	10	30	0,2	0	270	2,68	1,38	0,08	-0,03	5,38	0,26	1,64	2,46	3,45	7,75
99	20 000	HM	0,90	0,02	5	10	30	0,2	0	270	2,92	2,04	0,12	-1,08	6,91	0,05	1,33	2,52	4,28	12,14
100	20 000	HM	0,90	0,04	5	10	30	0,2	0	270	2,98	2,16	0,13	-1,26	7,22	0,06	1,30	2,42	4,18	9,77
101	20 000	HM	0,90	0,06	5	10	30	0,2	0	270	3,01	2,09	0,13	-1,08	7,10	0,07	1,56	2,51	4,15	11,27
102	20 000	HM	0,90	0,01	5	10	30	0,2	0	270	3,07	2,27	0,14	-1,37	7,51	0,00	1,32	2,49	4,47	15,61
103	20 000	BM	0,10	0,04	5	10	30	0,2	0	270	3,15	1,68	0,10	-0,15	6,45	0,44	1,96	2,85	4,03	9,44
104	20 000	HM	0,70	0,06	5	10	30	0,2	0	270	3,20	2,02	0,12	-0,75	7,16	0,00	1,70	2,95	4,14	12,65
105	20 000	HM	0,70	0,02	5	10	30	0,2	0	270	3,21	2,29	0,14	-1,28	7,70	0,13	1,55	2,65	4,25	14,32
106	20 000	HM	0,70	0,04	5	10	30	0,2	0	270	3,26	2,29	0,14	-1,22	7,74	0,03	1,62	2,66	4,67	12,82
107	20 000	HM	0,70	0,01	5	10	30	0,2	0	270	3,40	2,56	0,16	-1,62	8,41	0,00	1,53	2,76	4,62	17,77
108	20 000	HM	0,90	0,08	5	10	30	0,2	0	270	3,41	2,34	0,14	-1,17	7,99	0,07	1,62	3,03	4,71	18,56
109	20 000	HM	0,50	0,02	5	10	30	0,2	0	270	3,42	2,45	0,15	-1,39	8,23	0,08	1,68	3,05	4,58	24,09
110	20 000	HM	0,50	0,04	5	10	30	0,2	0	270	3,48	2,34	0,14	-1,12	8,07	0,22	1,70	3,15	4,54	13,37
111	20 000	HM	0,50	0,01	5	10	30	0,2	0	270	3,52	2,50	0,15	-1,38	8,43	0,06	1,63	2,89	4,84	15,49
112	20 000	BM	0,10	0,06	5	10	30	0,2	0	270	3,68	1,79	0,11	0,16	7,19	0,46	2,37	3,20	4,80	9,08
113	20 000	HM	0,90	0,10	5	10	30	0,2	0	270	3,74	2,17	0,13	-0,51	7,99	0,07	2,17	3,38	5,24	11,63
114	20 000	HM	0,70	0,08	5	10	30	0,2	0	270	3,81	2,39	0,15	-0,86	8,49	0,07	1,95	3,22	5,31	14,68
115	20 000	HM	0,30	0,01	5	10	30	0,2	0	270	3,89	2,66	0,16	-1,33	9,11	0,08	2,09	3,27	5,11	19,03
116	20 000	HM	0,30	0,02	5	10	30	0,2	0	270	3,97	2,37	0,14	-0,67	8,61	0,48	2,15	3,51	5,39	13,87
117	20 000	HM	0,50	0,06	5	10	30	0,2	0	270	4,00	2,70	0,16	-1,30	9,29	0,12	2,09	3,35	5,43	20,58
118	20 000	HM	0,30	0,04	5	10	30	0,2	0	270	4,09	2,38	0,15	-0,59	8,76	0,15	2,37	3,50	5,33	18,01
119	20 000	HM	0,50	0,08	5	10	30	0,2	0	270	4,20	2,48	0,15	-0,65	9,06	0,48	2,35	3,77	5,54	18,36
120	20 000	HM	0,70	0,10	5	10	30	0,2	0	270	4,28	2,49	0,15	-0,59	9,15	0,36	2,46	3,97	5,29	20,06
121	20 000	BM	0,10	0,08	5	10	30	0,2	0	270	4,38	1,94	0,12	0,58	8,18	1,06	3,01	4,04	5,54	11,79
122	20 000	HM	0,30	0,06	5	10	30	0,2	0	270	4,60	2,46	0,15	-0,22	9,42	0,90	2,79	4,12	6,02	13,57
123	20 000	HM	0,50	0,10	5	10	30	0,2	0	270	4,84	2,46	0,15	0,01	9,67	0,54	3,19	4,35	6,04	21,68
124	20 000	BM	0,10	0,10	5	10	30	0,2	0	270	4,98	2,02	0,12	1,03	8,94	0,70	3,42	4,69	6,23	11,37
125	20 000	HM	0,30	0,08	5	10	30	0,2	0	270	5,06	2,60	0,16	-0,05	10,16	0,44	3,21	4,57	6,57	22,86
126	20 000	HM	0,10	0,01	5	10	30	0,2	0	270	5,31	2,94	0,18	-0,46	11,08	0,57	3,17	4,84	6,96	25,00
127	20 000	HM	0,10	0,02	5	10	30	0,2	0	270	5,50	2,50	0,15	0,59	10,41	0,60	3,72	5,23	7,12	14,95
128	20 000	HM	0,30	0,10	5	10	30	0,2	0	270	5,69	2,54	0,15	0,71	10,67	0,70	3,89	5,47	7,14	15,70

Tab. C.1: Statystyki opisowe wyników algorytmu $\hat{S}_A$ dla $\hat{\Omega} = 30$ (c.d.)

#	$\hat{S}_A$	β	p_p	p_m	C	S	N	$\Delta_{\max}$	h	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	$-95[\%]$	$+95[\%]$	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
129	20 000	HM	0,10	0,04	5	10	30	0,2	0	270	6,07	2,70	0,16	0,78	11,37	0,94	4,11	5,77	7,92	18,94
130	20 000	BM	0,90	0,30	5	10	30	0,2	0	270	6,84	2,96	0,18	1,05	12,64	1,38	4,73	6,42	8,47	16,80
131	20 000	HM	0,10	0,06	5	10	30	0,2	0	270	6,87	2,69	0,16	1,60	12,13	1,91	4,90	6,60	8,33	16,30
132	20 000	BM	0,90	0,00	5	10	30	0,2	0	270	7,20	3,29	0,20	0,76	13,64	1,02	4,62	6,62	9,34	16,53
133	20 000	BM	0,30	0,00	5	10	30	0,2	0	270	7,39	3,26	0,20	0,99	13,78	1,33	4,73	7,18	9,41	17,25
134	20 000	BM	0,50	0,00	5	10	30	0,2	0	270	7,39	3,23	0,20	1,05	13,72	0,64	5,14	6,83	9,22	17,54
135	20 000	BM	0,70	0,00	5	10	30	0,2	0	270	7,42	3,32	0,20	0,92	13,93	0,59	4,98	7,11	9,44	18,18
136	20 000	BM	0,70	0,30	5	10	30	0,2	0	270	7,51	3,07	0,19	1,50	13,53	1,80	5,32	6,89	9,34	17,93
137	20 000	HM	0,10	0,08	5	10	30	0,2	0	270	7,65	2,85	0,17	2,07	13,23	1,60	5,65	7,45	9,25	18,42
138	20 000	BM	0,50	0,30	5	10	30	0,2	0	270	8,32	3,37	0,21	1,71	14,93	2,55	5,89	7,75	10,25	21,00
139	20 000	BM	0,10	0,00	5	10	30	0,2	0	270	8,42	3,25	0,20	2,05	14,79	1,38	6,07	8,16	10,32	18,91
140	20 000	HM	0,10	0,10	5	10	30	0,2	0	270	8,52	3,20	0,19	2,25	14,79	2,32	6,23	8,17	10,38	25,23
141	20 000	BM	0,30	0,30	5	10	30	0,2	0	270	9,77	3,72	0,23	2,48	17,06	2,90	7,10	9,14	12,06	23,24
142	20 000	HM	0,90	0,30	5	10	30	0,2	0	270	10,25	3,56	0,22	3,27	17,22	2,19	7,80	9,78	12,31	22,32
143	20 000	HM	0,70	0,30	5	10	30	0,2	0	270	10,79	3,83	0,23	3,29	18,29	3,70	7,78	10,57	13,19	22,88
144	20 000	HM	0,90	0,00	5	10	30	0,2	0	270	10,82	4,53	0,28	1,95	19,69	2,21	7,67	10,15	13,36	29,02
145	20 000	HM	0,50	0,00	5	10	30	0,2	0	270	11,02	4,57	0,28	2,06	19,98	2,16	7,44	10,47	13,66	26,08
146	20 000	HM	0,70	0,00	5	10	30	0,2	0	270	11,09	4,75	0,29	1,78	20,40	0,58	7,63	10,31	13,70	33,05
147	20 000	HM	0,30	0,00	5	10	30	0,2	0	270	11,35	4,66	0,28	2,22	20,48	2,61	7,84	10,37	14,23	26,49
148	20 000	HM	0,50	0,30	5	10	30	0,2	0	270	11,51	3,55	0,22	4,55	18,46	4,08	8,90	11,11	13,62	23,99
149	20 000	BM	0,10	0,30	5	10	30	0,2	0	270	12,16	4,06	0,25	4,21	20,11	4,67	9,18	11,28	15,07	26,07
150	20 000	HM	0,10	0,00	5	10	30	0,2	0	270	12,40	4,18	0,25	4,21	20,59	3,51	9,43	12,26	14,98	28,37
151	20 000	HM	0,30	0,30	5	10	30	0,2	0	270	12,42	3,80	0,23	4,99	19,86	3,94	9,80	12,09	14,61	23,75
152	20 000	BM	0,90	0,50	5	10	30	0,2	0	270	13,74	5,29	0,32	3,38	24,10	4,62	9,73	12,66	17,08	35,84
153	20 000	HM	0,10	0,30	5	10	30	0,2	0	270	14,14	3,82	0,23	6,66	21,63	5,01	11,47	14,09	16,51	27,51
154	20 000	BM	0,70	0,50	5	10	30	0,2	0	270	14,51	5,87	0,36	3,01	26,01	3,85	10,03	13,38	17,77	33,15
155	20 000	BM	0,50	0,50	5	10	30	0,2	0	270	14,86	5,62	0,34	3,85	25,87	3,38	11,01	13,64	18,12	35,59
156	20 000	BM	0,30	0,50	5	10	30	0,2	0	270	15,86	4,91	0,30	6,23	25,49	5,14	12,28	15,45	19,09	32,70
157	20 000	HM	0,90	0,50	5	10	30	0,2	0	270	15,99	4,85	0,30	6,48	25,50	5,69	12,57	15,28	19,04	31,33
158	20 000	HM	0,70	0,50	5	10	30	0,2	0	270	16,15	4,80	0,29	6,74	25,57	4,55	12,96	15,61	18,58	31,11
159	20 000	HM	0,50	0,50	5	10	30	0,2	0	270	16,53	4,69	0,29	7,34	25,72	6,39	13,22	16,05	19,07	33,46
160	20 000	BM	0,10	0,50	5	10	30	0,2	0	270	16,88	4,57	0,28	7,92	25,84	6,95	13,54	16,43	19,52	33,00

Tab. C.1: Statystyki opisowe wyników algorytmu $\mathbb{S}\mathbb{A}$ dla $\hat{\Omega} = 30$ (c.d.)

#	$\mathbb{S}\mathbb{A}$	β	p_p	p_m	C	S	N	$\Delta_{\max}$	h	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	$-95[\%]$	$+95[\%]$	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
161	20 000	HM	0,30	0,50	5	10	30	0,2	0	270	16,92	4,92	0,30	7,27	26,57	5,54	13,64	16,69	19,79	33,50
162	20 000	HM	0,10	0,50	5	10	30	0,2	0	270	17,60	4,57	0,28	8,65	26,55	6,36	14,50	17,12	20,33	33,01
163	20 000	BM	0,90	0,70	5	10	30	0,2	0	270	20,29	8,07	0,49	4,47	36,11	6,05	14,31	18,49	25,76	46,99
164	20 000	BM	0,70	0,70	5	10	30	0,2	0	270	20,47	7,57	0,46	5,64	35,31	5,63	15,12	19,36	24,69	49,69
165	20 000	HM	0,90	0,70	5	10	30	0,2	0	270	21,04	6,70	0,41	7,91	34,17	9,71	15,69	19,80	24,62	44,80
166	20 000	BM	0,50	0,70	5	10	30	0,2	0	270	21,33	7,32	0,45	6,99	35,67	7,78	15,97	20,30	25,36	50,09
167	20 000	BM	0,30	0,70	5	10	30	0,2	0	270	21,39	7,66	0,47	6,37	36,41	7,14	16,30	19,67	25,44	51,63
168	20 000	HM	0,70	0,70	5	10	30	0,2	0	270	21,45	7,32	0,45	7,10	35,79	8,27	16,22	20,33	25,30	50,14
169	20 000	HM	0,30	0,70	5	10	30	0,2	0	270	21,80	7,18	0,44	7,73	35,88	7,51	16,71	20,33	25,77	45,54
170	20 000	HM	0,50	0,70	5	10	30	0,2	0	270	22,05	7,34	0,45	7,67	36,43	8,99	16,75	20,88	25,08	47,91
171	20 000	BM	0,10	0,70	5	10	30	0,2	0	270	22,09	6,63	0,40	9,10	35,09	9,99	17,43	21,15	25,58	44,21
172	20 000	HM	0,10	0,70	5	10	30	0,2	0	270	22,35	6,62	0,40	9,38	35,32	9,94	17,99	21,19	26,17	47,52
173	20 000	BM	0,70	0,90	5	10	30	0,2	0	270	24,01	7,13	0,43	10,03	37,99	8,24	18,82	23,17	28,49	49,21
174	20 000	BM	0,50	0,90	5	10	30	0,2	0	270	24,55	7,27	0,44	10,30	38,80	11,01	18,80	24,06	28,75	50,28
175	20 000	BM	0,90	0,90	5	10	30	0,2	0	270	24,60	7,55	0,46	9,80	39,41	8,18	18,84	24,13	29,27	55,69
176	20 000	BM	0,10	0,90	5	10	30	0,2	0	270	24,86	7,10	0,43	10,94	38,78	9,05	19,52	23,82	28,95	42,95
177	20 000	HM	0,90	0,90	5	10	30	0,2	0	270	24,87	7,58	0,46	10,01	39,73	11,13	19,60	23,77	28,98	53,84
178	20 000	BM	0,30	0,90	5	10	30	0,2	0	270	25,05	6,93	0,42	11,47	38,63	10,43	20,13	24,20	29,23	48,60
179	20 000	HM	0,70	0,90	5	10	30	0,2	0	270	25,33	7,29	0,44	11,04	39,61	10,04	19,91	24,41	29,96	46,70
180	20 000	HM	0,10	0,90	5	10	30	0,2	0	270	25,47	6,52	0,40	12,70	38,24	10,91	21,28	24,80	29,18	49,56
181	20 000	HM	0,50	0,90	5	10	30	0,2	0	270	25,48	6,90	0,42	11,94	39,01	11,30	20,40	24,85	30,10	55,62
182	20 000	HM	0,30	0,90	5	10	30	0,2	0	270	25,58	7,35	0,45	11,18	39,98	11,97	20,24	24,64	29,70	57,82

Tab. C.2: Statystyki opisowe wyników algorytmu GA dla $\tilde{\Omega} = 30$

#	$\tilde{G}_A$	$\tilde{\mathcal{P}}$	$g_{\max}$	E	α	p_α	β	p_β	ϕ	ζ	n	$\overline{x}[\%]$	$s[\%]$	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
1	20 000	200	100	+	2PX	0,90	BM	0,04	T	2	270	0,77	0,70	0,04	-0,60	2,15	0,00	0,29	0,58	1,06	3,96
2	20 000	200	100	+	MIX	0,90	MM	0,10	T	4	270	0,78	0,71	0,04	-0,62	2,18	0,00	0,28	0,60	1,11	3,92
3	20 000	200	100	+	2PX	0,90	BM	0,02	T	2	270	0,83	0,74	0,05	-0,62	2,28	0,00	0,28	0,63	1,15	3,90
4	20 000	200	100	+	2PX	0,90	MM	0,04	T	2	270	0,84	0,81	0,05	-0,75	2,42	0,00	0,31	0,63	1,06	5,35
5	20 000	200	100	+	2PX	0,70	BM	0,04	T	2	270	0,85	0,76	0,05	-0,65	2,34	0,00	0,32	0,62	1,14	4,21
6	20 000	200	100	+	2PX	0,90	MM	0,02	T	2	270	0,88	0,86	0,05	-0,80	2,55	0,00	0,27	0,66	1,17	5,17
7	20 000	200	100	+	2PX	0,70	MM	0,04	T	2	270	0,88	0,81	0,05	-0,71	2,47	0,00	0,31	0,65	1,21	4,38
8	20 000	200	100	+	2PX	0,90	MM	0,06	T	2	270	0,88	0,69	0,04	-0,46	2,23	0,00	0,37	0,76	1,20	4,26
9	20 000	200	100	+	2PX	0,90	BM	0,06	T	2	270	0,88	0,61	0,04	-0,32	2,09	0,00	0,44	0,73	1,17	4,41
10	20 000	200	100	+	2PX	0,70	BM	0,06	T	2	270	0,89	0,64	0,04	-0,37	2,15	0,02	0,40	0,78	1,22	4,17
11	20 000	200	100	+	2PX	0,90	MM	0,08	T	2	270	0,89	0,68	0,04	-0,44	2,21	0,01	0,44	0,76	1,11	4,19
12	20 000	200	100	+	2PX	0,70	MM	0,06	T	2	270	0,90	0,70	0,04	-0,48	2,27	0,01	0,35	0,77	1,24	4,22
13	20 000	200	100	+	MIX	0,90	MM	0,10	T	3	270	0,92	0,73	0,04	-0,51	2,35	0,01	0,41	0,75	1,24	4,28
14	20 000	200	100	+	2PX	0,90	MM	0,10	T	2	270	0,93	0,64	0,04	-0,31	2,18	0,04	0,52	0,80	1,20	4,02
15	20 000	200	100	+	2PX	0,70	MM	0,08	T	2	270	0,96	0,70	0,04	-0,40	2,33	0,01	0,43	0,82	1,28	4,12
16	20 000	200	100	+	2PX	0,70	BM	0,02	T	2	270	0,97	0,83	0,05	-0,66	2,60	0,00	0,33	0,79	1,28	5,16
17	20 000	200	100	+	2PX	0,50	BM	0,06	T	2	270	0,99	0,66	0,04	-0,31	2,29	0,00	0,48	0,85	1,34	3,75
18	20 000	200	100	+	2PX	0,70	MM	0,10	T	2	270	0,99	0,66	0,04	-0,31	2,29	0,04	0,52	0,81	1,33	3,81
19	20 000	200	100	+	2PX	0,50	BM	0,04	T	2	270	0,99	0,84	0,05	-0,66	2,65	0,00	0,41	0,79	1,40	7,74
20	20 000	200	100	+	2PX	0,50	MM	0,04	T	2	270	0,99	0,84	0,05	-0,66	2,65	0,00	0,38	0,77	1,43	5,74
21	20 000	200	100	+	MIX	0,70	BM	0,02	T	2	270	1,00	0,85	0,05	-0,67	2,67	0,00	0,41	0,75	1,37	4,55
22	20 000	200	100	-	2PX	0,90	BM	0,02	T	2	270	1,00	0,87	0,05	-0,70	2,71	0,00	0,36	0,82	1,33	5,72
23	20 000	200	100	+	2PX	0,90	BM	0,08	T	2	270	1,02	0,64	0,04	-0,24	2,27	0,01	0,53	0,91	1,34	3,55
24	20 000	200	100	+	2PX	0,70	MM	0,02	T	2	270	1,02	0,97	0,06	-0,89	2,93	0,00	0,37	0,77	1,35	7,63
25	20 000	200	100	+	2PX	0,70	BM	0,08	T	2	270	1,03	0,64	0,04	-0,23	2,29	0,07	0,55	0,93	1,36	3,56
26	20 000	200	100	+	2PX	0,50	MM	0,06	T	2	270	1,05	0,85	0,05	-0,62	2,73	0,00	0,41	0,89	1,47	4,97
27	20 000	200	100	+	2PX	0,50	MM	0,08	T	2	270	1,08	0,86	0,05	-0,61	2,77	0,01	0,46	0,87	1,48	4,78
28	20 000	200	100	+	MIX	0,50	MM	0,04	T	2	270	1,08	0,95	0,06	-0,79	2,94	0,00	0,40	0,84	1,38	4,78
29	20 000	200	100	+	2PX	0,50	BM	0,08	T	2	270	1,09	0,71	0,04	-0,30	2,49	0,02	0,56	0,96	1,43	3,61
30	20 000	200	100	+	2PX	0,50	BM	0,02	T	2	270	1,10	0,88	0,05	-0,62	2,82	0,00	0,50	0,95	1,43	5,62
31	20 000	200	100	+	MIX	0,50	BM	0,04	T	2	270	1,10	0,81	0,05	-0,49	2,70	0,00	0,52	0,94	1,53	5,06
32	20 000	200	100	+	MIX	0,50	BM	0,02	T	2	270	1,11	0,85	0,05	-0,56	2,78	0,00	0,49	0,95	1,49	4,70

Tab. C.2: Statystyki opisowe wyników algorytmu $\mathbb{G}\mathbb{A}$ dla $\tilde{\Omega} = 30$ (c.d.)

#	$\mathbb{G}\mathbb{A}$	$\mathcal{S}$	$g_{\max}$	E	α	p_α	β	p_β	ϕ	ζ	n	$\bar{\pi}[\%]$	$s[\%]$	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
33	20 000	200	100	+	MIX	0,70	MM	0,02	T	2	270	1,11	0,98	0,06	-0,82	3,04	0,00	0,43	0,82	1,56	5,61
34	20 000	200	100	+	MIX	0,70	MM	0,04	T	2	270	1,11	0,95	0,06	-0,75	2,97	0,00	0,47	0,84	1,50	6,16
35	20 000	200	100	+	MIX	0,50	MM	0,06	T	2	270	1,12	0,86	0,05	-0,57	2,80	0,02	0,47	0,91	1,47	4,58
36	20 000	200	100	+	MIX	0,90	BM	0,02	T	2	270	1,12	0,95	0,06	-0,75	2,98	0,00	0,46	0,89	1,44	5,21
37	20 000	200	100	+	2PX	0,50	MM	0,10	T	2	270	1,12	0,69	0,04	-0,23	2,47	0,04	0,63	1,00	1,47	3,67
38	20 000	200	100	-	MIX	0,90	MM	0,10	T	4	270	1,13	0,89	0,05	-0,61	2,87	0,03	0,51	0,88	1,51	4,78
39	20 000	200	100	-	2PX	0,90	BM	0,04	T	2	270	1,13	0,83	0,05	-0,50	2,77	0,00	0,51	0,94	1,49	4,68
40	20 000	200	100	+	2PX	0,90	BM	0,10	T	2	270	1,13	0,63	0,04	-0,11	2,38	0,15	0,65	1,05	1,52	4,07
41	20 000	100	200	+	2PX	0,90	MM	0,10	T	2	270	1,17	0,81	0,05	-0,42	2,76	0,00	0,54	0,99	1,56	5,59
42	20 000	100	200	+	MIX	0,90	MM	0,10	T	3	270	1,17	0,98	0,06	-0,75	3,08	0,00	0,51	0,87	1,58	6,84
43	20 000	200	100	+	MIX	0,70	BM	0,04	T	2	270	1,17	0,84	0,05	-0,47	2,81	0,02	0,56	1,02	1,61	4,83
44	20 000	200	100	+	2PX	0,70	BM	0,10	T	2	270	1,17	0,67	0,04	-0,13	2,48	0,14	0,69	1,05	1,56	3,61
45	20 000	200	100	+	MIX	0,50	BM	0,06	T	2	270	1,17	0,80	0,05	-0,38	2,73	0,06	0,56	0,98	1,67	4,50
46	20 000	100	200	+	MIX	0,90	MM	0,10	T	4	270	1,18	0,95	0,06	-0,68	3,03	0,00	0,46	0,97	1,58	4,67
47	20 000	200	100	+	MIX	0,90	MM	0,02	T	2	270	1,18	1,03	0,06	-0,83	3,19	0,00	0,50	0,95	1,50	5,84
48	20 000	200	100	+	MIX	0,70	BM	0,06	T	2	270	1,22	0,80	0,05	-0,35	2,78	0,06	0,62	1,10	1,53	4,21
49	20 000	200	100	+	MIX	0,50	MM	0,08	T	2	270	1,22	0,82	0,05	-0,38	2,82	0,06	0,64	1,06	1,59	4,37
50	20 000	200	100	+	2PX	0,50	BM	0,10	T	2	270	1,22	0,74	0,04	-0,22	2,67	0,12	0,70	1,06	1,64	4,62
51	20 000	200	100	+	MIX	0,90	MM	0,04	T	2	270	1,23	1,02	0,06	-0,77	3,23	0,01	0,55	0,99	1,61	5,93
52	20 000	200	100	+	MIX	0,70	MM	0,06	T	2	270	1,25	0,94	0,06	-0,59	3,09	0,03	0,54	1,05	1,60	4,42
53	20 000	200	100	+	MIX	0,50	MM	0,02	T	2	270	1,26	1,10	0,07	-0,89	3,40	0,00	0,50	1,03	1,73	7,22
54	20 000	200	100	+	2PX	0,50	MM	0,02	T	2	270	1,26	1,00	0,06	-0,70	3,23	0,00	0,51	1,03	1,74	6,02
55	20 000	200	100	+	MIX	0,90	BM	0,04	T	2	270	1,27	0,92	0,06	-0,53	3,07	0,05	0,63	1,10	1,61	4,83
56	20 000	200	100	-	2PX	0,90	MM	0,06	T	2	270	1,27	0,86	0,05	-0,42	2,96	0,06	0,70	1,11	1,55	5,80
57	20 000	400	50	+	2PX	0,90	MM	0,10	T	2	270	1,27	0,72	0,04	-0,13	2,68	0,14	0,78	1,14	1,55	4,25
58	20 000	100	200	+	2PX	0,90	BM	0,10	T	2	270	1,28	0,81	0,05	-0,32	2,87	0,04	0,69	1,09	1,72	4,03
59	20 000	200	100	+	2PX	0,90	HM	0,06	T	2	270	1,29	1,04	0,06	-0,76	3,33	0,01	0,52	1,03	1,76	6,67
60	20 000	200	100	+	MIX	0,70	MM	0,08	T	2	270	1,30	0,87	0,05	-0,41	3,00	0,04	0,69	1,07	1,71	5,16
61	20 000	200	100	+	2PX	0,90	HM	0,10	T	2	270	1,30	1,03	0,06	-0,72	3,32	0,01	0,61	1,04	1,71	6,63
62	20 000	200	100	+	2PX	0,90	HM	0,08	T	2	270	1,31	1,15	0,07	-0,94	3,56	0,00	0,59	0,96	1,69	8,80
63	20 000	200	100	+	MIX	0,30	BM	0,04	T	2	270	1,31	0,94	0,06	-0,53	3,15	0,01	0,64	1,07	1,87	4,61
64	20 000	200	100	+	MIX	0,50	MM	0,10	T	2	270	1,31	0,87	0,05	-0,40	3,02	0,12	0,73	1,12	1,70	6,47

Tab. C.2: Statystyki opisowe wyników algorytmu GA dla $\tilde{\Omega} = 30$ (c.d.)

#	$\tilde{G}_A$	$\tilde{\mathcal{P}}$	$g_{\max}$	E	α	p_α	β	p_β	ϕ	ζ	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
65	20 000	200	100	+	MIX	0,90	MM	0,06	T	2	270	1,33	0,95	0,06	-0,53	3,19	0,03	0,70	1,10	1,72	4,94
66	20 000	200	100	+	MIX	0,50	BM	0,08	T	2	270	1,34	0,83	0,05	-0,29	2,96	0,07	0,85	1,16	1,67	6,94
67	20 000	200	100	+	2PX	0,70	HM	0,06	T	2	270	1,34	1,11	0,07	-0,84	3,51	0,00	0,56	1,06	1,84	9,22
68	20 000	200	100	+	MIX	0,70	MM	0,10	T	2	270	1,35	0,88	0,05	-0,37	3,08	0,09	0,76	1,15	1,74	5,51
69	20 000	200	100	+	2PX	0,30	MM	0,06	T	2	270	1,37	0,96	0,06	-0,52	3,26	0,00	0,65	1,16	1,90	5,13
70	20 000	200	100	+	MIX	0,70	BM	0,08	T	2	270	1,37	0,84	0,05	-0,28	3,02	0,16	0,77	1,25	1,70	4,82
71	20 000	200	100	+	MIX	0,30	MM	0,08	T	2	270	1,37	0,91	0,06	-0,41	3,16	0,05	0,72	1,20	1,84	4,69
72	20 000	200	100	+	2PX	0,70	HM	0,10	T	2	270	1,38	1,10	0,07	-0,78	3,53	0,00	0,63	1,07	1,78	6,40
73	20 000	200	100	+	2PX	0,30	BM	0,04	T	2	270	1,38	1,12	0,07	-0,81	3,56	0,00	0,59	1,09	1,84	6,55
74	20 000	200	100	+	MIX	0,30	MM	0,06	T	2	270	1,38	1,04	0,06	-0,66	3,42	0,04	0,66	1,21	1,84	7,50
75	20 000	200	100	+	2PX	0,90	HM	0,04	T	2	270	1,38	1,09	0,07	-0,76	3,53	0,00	0,58	1,14	1,96	6,47
76	20 000	200	100	+	MIX	0,30	BM	0,06	T	2	270	1,39	0,90	0,05	-0,37	3,16	0,10	0,71	1,25	1,95	4,96
77	20 000	200	100	+	MIX	0,90	BM	0,06	T	2	270	1,39	0,88	0,05	-0,33	3,12	0,12	0,76	1,27	1,80	4,97
78	20 000	200	100	+	2PX	0,30	BM	0,06	T	2	270	1,40	1,00	0,06	-0,56	3,36	0,13	0,66	1,19	1,92	5,67
79	20 000	200	100	+	MIX	0,30	MM	0,04	T	2	270	1,41	1,03	0,06	-0,60	3,43	0,01	0,67	1,27	1,84	8,06
80	20 000	200	100	+	2PX	0,30	MM	0,10	T	2	270	1,41	0,83	0,05	-0,21	3,04	0,07	0,75	1,24	1,91	4,42
81	20 000	200	100	+	2PX	0,30	MM	0,04	T	2	270	1,42	1,09	0,07	-0,72	3,56	0,00	0,60	1,14	2,09	6,02
82	20 000	200	100	+	MIX	0,90	MM	0,08	T	2	270	1,42	0,92	0,06	-0,38	3,22	0,09	0,78	1,21	1,76	5,06
83	20 000	200	100	+	1PX	0,90	MM	0,10	T	2	270	1,42	0,90	0,05	-0,35	3,19	0,03	0,78	1,17	1,95	4,51
84	20 000	200	100	+	2PX	0,70	HM	0,08	T	2	270	1,44	1,24	0,08	-0,99	3,86	0,00	0,66	1,11	1,86	8,87
85	20 000	100	200	+	MIX	0,90	MM	0,10	T	2	270	1,45	0,99	0,06	-0,50	3,39	0,07	0,76	1,24	1,85	5,37
86	20 000	200	100	+	MIX	0,50	BM	0,10	T	2	270	1,45	0,85	0,05	-0,22	3,13	0,16	0,88	1,30	1,77	6,19
87	20 000	200	100	+	2PX	0,30	BM	0,08	T	2	270	1,46	0,93	0,06	-0,36	3,29	0,12	0,77	1,29	1,94	5,21
88	20 000	200	100	+	MIX	0,30	MM	0,10	T	2	270	1,47	0,88	0,05	-0,26	3,20	0,09	0,85	1,26	2,03	5,43
89	20 000	200	100	+	2PX	0,30	MM	0,08	T	2	270	1,47	0,99	0,06	-0,46	3,40	0,01	0,76	1,28	1,85	5,67
90	20 000	200	100	+	2PX	0,50	HM	0,10	T	2	270	1,49	1,12	0,07	-0,70	3,68	0,03	0,67	1,19	1,96	7,33
91	20 000	400	50	+	2PX	0,90	BM	0,10	T	2	270	1,49	0,73	0,04	0,05	2,93	0,33	0,97	1,37	1,82	4,57
92	20 000	200	100	+	MIX	0,90	BM	0,08	T	2	270	1,51	0,90	0,05	-0,26	3,27	0,15	0,91	1,35	1,90	6,12
93	20 000	200	100	+	2PX	0,90	HM	0,02	T	2	270	1,51	1,18	0,07	-0,81	3,82	0,00	0,72	1,17	1,97	7,56
94	20 000	200	100	+	MIX	0,90	MM	0,10	T	2	270	1,51	1,03	0,06	-0,51	3,54	0,17	0,80	1,27	1,88	7,43
95	20 000	200	100	+	PSX	0,90	HM	0,10	T	2	270	1,52	1,19	0,07	-0,82	3,85	0,05	0,63	1,16	2,15	6,00
96	20 000	200	100	-	2PX	0,90	MM	0,08	T	2	270	1,52	0,87	0,05	-0,19	3,23	0,17	0,88	1,35	1,95	6,14

Tab. C.2: Statystyki opisowe wyników algorytmu $\mathbb{GA}$ dla $\hat{\Omega} = 30$ (c.d.)

#	$\mathbb{GA}$	$\mathcal{S}$	$g_{\max}$	E	α	p_α	β	p_β	ϕ	ζ	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
97	20 000	200	100	+	MIX	0,70	BM	0,10	T	2	270	1,52	0,84	0,05	-0,12	3,17	0,14	0,93	1,38	1,98	4,85
98	20 000	200	100	+	IPX	0,90	BM	0,10	T	2	270	1,53	0,83	0,05	-0,09	3,16	0,22	0,98	1,35	1,95	5,28
99	20 000	200	100	+	MIX	0,30	BM	0,02	T	2	270	1,55	1,16	0,07	-0,74	3,83	0,00	0,68	1,28	2,19	7,53
100	20 000	400	50	+	2PX	0,90	HM	0,10	T	2	270	1,55	1,02	0,06	-0,45	3,55	0,12	0,92	1,34	1,96	6,44
101	20 000	100	200	-	MIX	0,90	MM	0,10	T	4	270	1,55	0,98	0,06	-0,37	3,48	0,05	0,85	1,35	2,12	5,43
102	20 000	200	100	+	MIX	0,70	HM	0,08	T	2	270	1,56	1,22	0,07	-0,84	3,95	0,03	0,71	1,30	2,04	9,24
103	20 000	200	100	-	MIX	0,90	MM	0,10	T	3	270	1,56	1,02	0,06	-0,45	3,57	0,08	0,87	1,32	1,94	5,96
104	20 000	200	100	+	MIX	0,30	BM	0,08	T	2	270	1,57	1,00	0,06	-0,39	3,53	0,06	0,91	1,38	1,97	6,47
105	20 000	200	100	+	MIX	0,30	BM	0,10	T	2	270	1,58	0,90	0,05	-0,18	3,33	0,16	1,00	1,41	2,07	5,49
106	20 000	200	100	+	2PX	0,70	HM	0,04	T	2	270	1,58	1,34	0,08	-1,04	4,21	0,00	0,70	1,28	2,06	10,28
107	20 000	200	100	+	2PX	0,30	BM	0,10	T	2	270	1,59	0,91	0,06	-0,20	3,37	0,09	0,91	1,43	2,09	4,89
108	20 000	200	100	+	MIX	0,30	MM	0,02	T	2	270	1,59	1,07	0,07	-0,51	3,69	0,00	0,80	1,32	2,15	6,52
109	20 000	200	100	+	2PX	0,50	HM	0,08	T	2	270	1,60	1,21	0,07	-0,78	3,98	0,05	0,77	1,34	2,09	7,27
110	20 000	100	200	+	PSX	0,90	HM	0,10	T	2	270	1,60	1,28	0,08	-0,91	4,12	0,00	0,71	1,30	2,16	6,59
111	20 000	200	100	+	2PX	0,30	BM	0,02	T	2	270	1,61	1,16	0,07	-0,68	3,89	0,00	0,71	1,35	2,22	5,79
112	20 000	100	200	+	IPX	0,90	MM	0,10	T	2	270	1,61	1,09	0,07	-0,54	3,75	0,04	0,85	1,33	2,11	6,33
113	20 000	200	100	+	2PX	0,50	HM	0,06	T	2	270	1,61	1,23	0,08	-0,81	4,03	0,00	0,71	1,32	2,11	6,18
114	20 000	100	200	+	MIX	0,90	BM	0,10	T	2	270	1,61	0,91	0,06	-0,17	3,40	0,07	0,97	1,47	2,05	5,81
115	20 000	200	100	+	2PX	0,70	HM	0,30	T	2	270	1,61	0,91	0,06	-0,17	3,40	0,15	0,99	1,43	1,99	6,85
116	20 000	200	100	+	MIX	0,90	BM	0,10	T	2	270	1,63	0,87	0,05	-0,08	3,34	0,15	1,04	1,46	2,07	5,20
117	20 000	200	100	+	MIX	0,50	HM	0,06	T	2	270	1,65	1,35	0,08	-1,01	4,30	0,00	0,75	1,34	2,17	12,54
118	20 000	200	100	+	MIX	0,70	HM	0,06	T	2	270	1,65	1,40	0,09	-1,09	4,39	0,00	0,71	1,22	2,20	8,20
119	20 000	100	200	+	2PX	0,90	HM	0,10	T	2	270	1,65	1,35	0,08	-1,00	4,29	0,03	0,71	1,43	2,05	10,50
120	20 000	200	100	+	MIX	0,50	HM	0,08	T	2	270	1,66	1,34	0,08	-0,97	4,28	0,05	0,77	1,25	2,09	7,87
121	20 000	200	100	+	MIX	0,50	HM	0,10	T	2	270	1,66	1,12	0,07	-0,53	3,85	0,01	0,85	1,39	2,11	6,29
122	20 000	200	100	+	2PX	0,90	HM	0,30	T	2	270	1,66	0,95	0,06	-0,19	3,52	0,21	0,94	1,43	2,12	6,33
123	20 000	200	100	+	2PX	0,30	MM	0,02	T	2	270	1,67	1,11	0,07	-0,50	3,84	0,00	0,78	1,56	2,28	5,50
124	20 000	200	100	+	MIX	0,70	HM	0,10	T	2	270	1,67	1,24	0,08	-0,76	4,09	0,01	0,87	1,34	2,15	7,73
125	20 000	200	100	+	MIX	0,90	HM	0,06	T	2	270	1,67	1,36	0,08	-0,99	4,33	0,02	0,83	1,37	2,20	12,93
126	20 000	100	200	-	MIX	0,90	MM	0,10	T	3	270	1,70	0,98	0,06	-0,21	3,61	0,02	1,02	1,55	2,09	5,18
127	20 000	200	100	-	2PX	0,90	HM	0,02	T	2	270	1,70	1,30	0,08	-0,85	4,25	0,00	0,75	1,38	2,31	6,96
128	20 000	200	100	-	2PX	0,90	MM	0,10	T	2	270	1,70	0,89	0,05	-0,04	3,44	0,11	1,15	1,47	2,03	5,71

Tab. C.2: Statystyki opisowe wyników algorytmu GA dla $\tilde{\Omega} = 30$ (c.d.)

#	$\tilde{G}_A$	$\tilde{\mathcal{P}}$	$g_{\max}$	E	α	p_α	β	p_β	ϕ	ζ	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
129	20 000	200	100	-	2PX	0,90	HM	0,08	T	2	270	1,71	1,13	0,07	-0,51	3,93	0,07	0,91	1,42	2,34	5,91
130	20 000	200	100	+	2PX	0,50	HM	0,30	T	2	270	1,72	0,92	0,06	-0,08	3,53	0,19	1,06	1,59	2,15	7,08
131	20 000	400	50	+	1PX	0,90	MM	0,10	T	2	270	1,74	0,96	0,06	-0,13	3,61	0,17	1,05	1,58	2,21	5,43
132	20 000	100	200	+	PSX	0,90	MM	0,10	T	2	270	1,74	1,21	0,07	-0,64	4,13	0,02	0,88	1,51	2,12	7,07
133	20 000	200	100	+	MIX	0,90	HM	0,08	T	2	270	1,75	1,36	0,08	-0,91	4,41	0,07	0,82	1,35	2,30	7,89
134	20 000	100	200	+	1PX	0,90	BM	0,10	T	2	270	1,75	1,04	0,06	-0,29	3,80	0,00	0,96	1,62	2,30	7,21
135	20 000	200	100	+	MIX	0,90	HM	0,04	T	2	270	1,76	1,42	0,09	-1,01	4,54	0,00	0,75	1,34	2,46	8,01
136	20 000	200	100	+	MIX	0,90	HM	0,10	T	2	270	1,76	1,47	0,09	-1,11	4,64	0,05	0,92	1,36	2,11	13,95
137	20 000	200	100	+	1PX	0,90	HM	0,10	T	2	270	1,77	1,23	0,07	-0,64	4,18	0,07	0,89	1,55	2,36	8,22
138	20 000	200	100	-	2PX	0,90	HM	0,10	T	2	270	1,77	1,07	0,07	-0,33	3,87	0,21	1,02	1,47	2,30	6,15
139	20 000	200	100	+	MIX	0,70	HM	0,04	T	2	270	1,78	1,42	0,09	-1,00	4,56	0,02	0,84	1,48	2,31	10,23
140	20 000	200	100	+	MIX	0,70	HM	0,02	T	2	270	1,79	1,32	0,08	-0,80	4,38	0,00	0,90	1,56	2,28	8,86
141	20 000	200	100	+	2PX	0,50	HM	0,04	T	2	270	1,80	1,37	0,08	-0,87	4,48	0,00	0,79	1,43	2,43	7,46
142	20 000	200	100	+	MIX	0,50	HM	0,04	T	2	270	1,82	1,46	0,09	-1,04	4,68	0,00	0,82	1,51	2,33	8,94
143	20 000	400	50	-	2PX	0,90	HM	0,10	T	2	270	1,83	1,12	0,07	-0,37	4,03	0,27	1,04	1,56	2,31	6,70
144	20 000	200	100	+	2PX	0,70	HM	0,02	T	2	270	1,84	1,43	0,09	-0,97	4,65	0,00	0,80	1,41	2,57	6,97
145	20 000	200	100	+	MIX	0,90	HM	0,02	T	2	270	1,85	1,39	0,08	-0,88	4,58	0,00	0,79	1,60	2,46	7,98
146	20 000	400	50	+	MIX	0,90	MM	0,10	T	2	270	1,85	1,05	0,06	-0,21	3,92	0,23	1,10	1,60	2,40	5,47
147	20 000	50	400	+	2PX	0,90	MM	0,10	T	2	270	1,86	1,25	0,08	-0,60	4,31	0,00	0,90	1,67	2,50	9,20
148	20 000	400	50	-	2PX	0,90	MM	0,10	T	2	270	1,86	0,88	0,05	0,12	3,59	0,44	1,22	1,71	2,26	6,43
149	20 000	400	50	+	1PX	0,90	BM	0,10	T	2	270	1,87	0,90	0,05	0,10	3,64	0,26	1,25	1,72	2,33	6,15
150	20 000	200	100	+	2PX	0,30	HM	0,10	T	2	270	1,87	1,28	0,08	-0,64	4,38	0,06	0,90	1,55	2,45	7,46
151	20 000	200	100	+	MIX	0,50	HM	0,30	T	2	270	1,89	1,07	0,06	-0,20	3,98	0,22	1,17	1,66	2,36	7,91
152	20 000	200	100	+	MIX	0,30	HM	0,10	T	2	270	1,92	1,30	0,08	-0,63	4,46	0,04	1,06	1,61	2,48	7,29
153	20 000	100	200	+	MIX	0,90	HM	0,10	T	2	270	1,92	1,29	0,08	-0,60	4,44	0,04	0,99	1,63	2,56	6,89
154	20 000	200	100	+	PSX	0,90	MM	0,10	T	2	270	1,93	1,23	0,07	-0,47	4,34	0,11	1,03	1,63	2,46	6,64
155	20 000	400	50	+	PSX	0,90	HM	0,10	T	2	270	1,94	1,23	0,07	-0,47	4,35	0,29	0,92	1,68	2,70	6,64
156	20 000	200	100	+	2PX	0,50	MM	0,30	T	2	270	1,95	0,83	0,05	0,33	3,58	0,43	1,36	1,76	2,39	4,84
157	20 000	200	100	+	2PX	0,70	MM	0,30	T	2	270	1,96	0,82	0,05	0,34	3,57	0,45	1,40	1,80	2,38	5,75
158	20 000	400	50	+	MIX	0,90	HM	0,10	T	2	270	1,96	1,28	0,08	-0,56	4,47	0,23	1,15	1,66	2,54	11,71
159	20 000	100	200	+	PSX	0,90	BM	0,10	T	2	270	1,96	1,14	0,07	-0,28	4,19	0,10	1,06	1,82	2,54	6,12
160	20 000	50	400	+	MIX	0,90	BM	0,10	T	2	270	1,97	1,23	0,07	-0,44	4,38	0,12	1,16	1,70	2,57	8,67

Tab. C.2: Statystyki opisowe wyników algorytmu $\mathbb{GA}$ dla $\hat{\Omega} = 30$ (c.d.)

#	$\mathbb{GA}$	$\mathcal{S}$	$g_{\max}$	E	α	p_α	β	p_β	ϕ	ζ	n	$\bar{\pi}[\%]$	$s[\%]$	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
161	20 000	200	100	+	2PX	0,90	MM	0,30	T	2	270	1,97	0,88	0,05	0,24	3,71	0,60	1,34	1,74	2,45	5,18
162	20 000	200	100	+	MIX	0,70	HM	0,30	T	2	270	1,99	1,11	0,07	-0,19	4,16	0,33	1,25	1,76	2,47	8,37
163	20 000	400	50	+	1PX	0,90	HM	0,10	T	2	270	2,00	1,38	0,08	-0,70	4,70	0,20	1,06	1,71	2,52	11,27
164	20 000	200	100	+	2PX	0,30	HM	0,08	T	2	270	2,00	1,39	0,08	-0,73	4,73	0,04	0,97	1,68	2,70	8,13
165	20 000	50	400	+	MIX	0,90	MM	0,10	T	2	270	2,01	1,24	0,08	-0,41	4,44	0,11	1,05	1,82	2,65	7,50
166	20 000	200	100	+	2PX	0,30	HM	0,30	T	2	270	2,02	1,08	0,07	-0,09	4,13	0,23	1,21	1,81	2,66	6,47
167	20 000	200	100	+	MIX	0,50	HM	0,02	T	2	270	2,03	1,57	0,10	-1,04	5,10	0,02	1,04	1,75	2,52	13,09
168	20 000	200	100	+	MIX	0,30	HM	0,08	T	2	270	2,03	1,45	0,09	-0,82	4,88	0,03	0,96	1,76	2,82	8,47
169	20 000	400	50	+	MIX	0,90	BM	0,10	T	2	270	2,03	1,00	0,06	0,08	3,99	0,40	1,27	1,86	2,55	6,26
170	20 000	50	400	+	2PX	0,90	BM	0,10	T	2	270	2,06	1,23	0,07	-0,35	4,46	0,01	1,10	1,89	2,85	6,05
171	20 000	200	100	+	2PX	0,30	HM	0,06	T	2	270	2,06	1,46	0,09	-0,81	4,92	0,01	1,02	1,74	2,77	11,29
172	20 000	50	400	+	MIX	0,90	MM	0,10	T	3	270	2,06	1,35	0,08	-0,59	4,71	0,00	1,11	1,79	2,74	9,98
173	20 000	200	100	+	MIX	0,90	HM	0,30	T	2	270	2,08	1,15	0,07	-0,19	4,34	0,15	1,27	1,78	2,65	6,71
174	20 000	200	100	+	MIX	0,30	HM	0,30	T	2	270	2,08	1,13	0,07	-0,13	4,29	0,26	1,26	1,83	2,61	6,78
175	20 000	100	200	-	2PX	0,90	MM	0,10	T	2	270	2,11	1,11	0,07	-0,07	4,29	0,39	1,32	1,86	2,56	6,34
176	20 000	200	100	+	2PX	0,50	HM	0,02	T	2	270	2,11	1,36	0,08	-0,56	4,78	0,00	1,05	1,90	2,84	8,37
177	20 000	100	200	-	2PX	0,90	HM	0,10	T	2	270	2,11	1,38	0,08	-0,59	4,81	0,06	1,17	1,76	2,72	10,69
178	20 000	200	100	+	MIX	0,30	HM	0,06	T	2	270	2,11	1,61	0,10	-1,04	5,26	0,00	0,96	1,72	2,78	11,89
179	20 000	200	100	+	MIX	0,50	MM	0,30	T	2	270	2,14	0,92	0,06	0,33	3,96	0,51	1,41	2,01	2,80	5,05
180	20 000	50	400	+	PSX	0,90	BM	0,10	T	2	270	2,16	1,25	0,08	-0,29	4,61	0,09	1,23	2,01	2,81	6,96
181	20 000	200	100	+	2PX	0,70	HM	0,50	T	2	270	2,18	0,99	0,06	0,23	4,13	0,40	1,49	1,97	2,70	6,97
182	20 000	200	100	+	2PX	0,90	HM	0,50	T	2	270	2,19	0,98	0,06	0,26	4,11	0,62	1,45	2,04	2,71	5,91
183	20 000	200	100	+	2PX	0,30	MM	0,30	T	2	270	2,20	1,01	0,06	0,21	4,18	0,39	1,50	2,03	2,75	6,51
184	20 000	200	100	+	2PX	0,50	HM	0,50	T	2	270	2,21	0,94	0,06	0,37	4,04	0,36	1,58	2,04	2,75	5,74
185	20 000	50	400	+	PSX	0,90	MM	0,10	T	2	270	2,21	1,54	0,09	-0,80	5,22	0,07	1,08	1,91	2,71	9,45
186	20 000	200	100	+	MIX	0,70	MM	0,30	T	2	270	2,22	1,04	0,06	0,18	4,25	0,46	1,48	2,00	2,75	7,18
187	20 000	200	100	+	MIX	0,30	MM	0,30	T	2	270	2,23	1,02	0,06	0,24	4,22	0,41	1,49	2,14	2,79	5,92
188	20 000	200	100	+	MIX	0,30	HM	0,04	T	2	270	2,25	1,53	0,09	-0,74	5,25	0,00	1,20	2,00	3,16	14,28
189	20 000	50	400	+	MIX	0,90	MM	0,10	T	4	270	2,26	1,58	0,10	-0,83	5,36	0,00	1,14	1,92	3,14	10,47
190	20 000	200	100	+	MIX	0,90	MM	0,30	T	2	270	2,27	0,99	0,06	0,33	4,20	0,47	1,55	2,07	2,87	5,99
191	20 000	200	100	-	1PX	0,90	HM	0,10	T	2	270	2,27	1,41	0,09	-0,49	5,03	0,28	1,25	1,87	2,84	8,19
192	20 000	200	100	+	MIX	0,10	MM	0,10	T	2	270	2,30	1,38	0,08	-0,40	5,01	0,16	1,30	1,98	3,05	8,38

Tab. C.2: Statystyki opisowe wyników algorytmu GA dla $\tilde{\Omega} = 30$ (c.d.)

#	$\tilde{G}_A$	$\tilde{\mathcal{P}}$	$g_{\max}$	E	α	p_α	β	p_β	ϕ	ζ	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
193	20 000	400	50	-	2PX	0,90	BM	0,10	T	2	270	2,30	0,96	0,06	0,42	4,19	0,51	1,64	2,13	2,77	6,56
194	20 000	200	100	+	2PX	0,30	HM	0,04	T	2	270	2,31	1,51	0,09	-0,65	5,28	0,01	1,21	1,98	3,07	7,39
195	20 000	200	100	-	2PX	0,90	BM	0,10	T	2	270	2,32	1,00	0,06	0,35	4,29	0,48	1,59	2,12	2,79	6,67
196	20 000	200	100	-	MIX	0,90	HM	0,10	T	2	270	2,33	1,54	0,09	-0,69	5,34	0,25	1,23	1,97	2,96	12,40
197	20 000	200	100	+	MIX	0,10	BM	0,10	T	2	270	2,33	1,28	0,08	-0,17	4,84	0,29	1,41	2,09	2,99	7,02
198	20 000	200	100	+	2PX	0,10	BM	0,06	T	2	270	2,36	1,51	0,09	-0,60	5,32	0,20	1,30	2,04	3,11	8,95
199	20 000	200	100	+	MIX	0,70	HM	0,50	T	2	270	2,37	1,10	0,07	0,22	4,52	0,61	1,58	2,17	2,89	7,55
200	20 000	400	50	-	1PX	0,90	HM	0,10	T	2	270	2,37	1,30	0,08	-0,18	4,92	0,50	1,44	2,13	2,94	9,41
201	20 000	200	100	+	MIX	0,10	MM	0,08	T	2	270	2,37	1,42	0,09	-0,42	5,16	0,14	1,33	2,15	3,09	7,74
202	20 000	200	100	+	PSX	0,90	BM	0,10	T	2	270	2,38	1,40	0,08	-0,36	5,11	0,30	1,37	2,03	3,00	8,30
203	20 000	200	100	+	MIX	0,50	HM	0,50	T	2	270	2,38	1,07	0,07	0,28	4,47	0,49	1,62	2,18	2,87	7,32
204	20 000	50	400	+	PSX	0,90	HM	0,10	T	2	270	2,39	1,55	0,09	-0,65	5,44	0,01	1,25	2,14	3,24	7,98
205	20 000	200	100	+	MIX	0,10	BM	0,04	T	2	270	2,39	1,55	0,09	-0,65	5,43	0,04	1,29	2,09	3,29	8,47
206	20 000	400	50	-	1PX	0,90	MM	0,10	T	2	270	2,40	1,20	0,07	0,05	4,75	0,73	1,56	2,08	2,99	8,82
207	20 000	200	100	-	1PX	0,90	MM	0,10	T	2	270	2,40	1,24	0,08	-0,03	4,82	0,37	1,48	2,16	2,98	7,10
208	20 000	200	100	+	MIX	0,10	BM	0,08	T	2	270	2,40	1,48	0,09	-0,49	5,29	0,25	1,33	2,13	3,10	10,07
209	20 000	200	100	+	MIX	0,90	HM	0,50	T	2	270	2,41	1,11	0,07	0,23	4,59	0,47	1,62	2,17	3,02	7,43
210	20 000	200	100	+	2PX	0,10	MM	0,06	T	2	270	2,41	1,45	0,09	-0,42	5,24	0,01	1,39	2,22	3,13	7,76
211	20 000	200	100	+	2PX	0,10	MM	0,10	T	2	270	2,43	1,34	0,08	-0,20	5,06	0,08	1,42	2,24	3,26	7,52
212	20 000	200	100	+	2PX	0,90	BM	0,30	T	2	270	2,44	1,03	0,06	0,42	4,46	0,68	1,67	2,26	3,09	6,34
213	20 000	200	100	+	2PX	0,10	BM	0,10	T	2	270	2,44	1,37	0,08	-0,24	5,13	0,26	1,45	2,17	3,28	9,88
214	20 000	200	100	+	2PX	0,30	HM	0,50	T	2	270	2,44	1,01	0,06	0,46	4,42	0,64	1,69	2,30	2,97	6,50
215	20 000	200	100	+	MIX	0,10	BM	0,06	T	2	270	2,45	1,48	0,09	-0,46	5,35	0,05	1,31	2,17	3,31	7,36
216	20 000	100	200	+	1PX	0,90	HM	0,10	T	2	270	2,45	1,70	0,10	-0,89	5,79	0,06	1,22	2,12	3,13	8,80
217	20 000	400	50	+	PSX	0,90	MM	0,10	T	2	270	2,46	1,43	0,09	-0,34	5,25	0,31	1,43	2,10	3,12	8,30
218	20 000	50	400	+	1PX	0,90	BM	0,10	T	2	270	2,46	1,58	0,10	-0,64	5,56	0,00	1,32	2,22	3,49	12,42
219	20 000	200	100	+	2PX	0,10	MM	0,08	T	2	270	2,47	1,46	0,09	-0,39	5,32	0,10	1,42	2,33	3,37	8,28
220	20 000	200	100	+	2PX	0,10	BM	0,08	T	2	270	2,47	1,50	0,09	-0,47	5,40	0,16	1,33	2,24	3,44	8,69
221	20 000	200	100	+	2PX	0,70	BM	0,30	T	2	270	2,49	1,01	0,06	0,50	4,47	0,75	1,76	2,31	3,09	6,16
222	20 000	50	400	+	2PX	0,90	HM	0,10	T	2	270	2,51	1,73	0,11	-0,87	5,90	0,00	1,34	2,01	3,42	9,23
223	20 000	200	100	+	MIX	0,30	HM	0,50	T	2	270	2,52	1,10	0,07	0,36	4,68	0,70	1,71	2,33	3,12	6,99
224	20 000	200	100	+	MIX	0,10	MM	0,06	T	2	270	2,52	1,61	0,10	-0,62	5,67	0,09	1,27	2,19	3,14	8,76

Tab. C.2: Statystyki opisowe wyników algorytmu $\mathbb{GA}$ dla $\hat{\Omega} = 30$ (c.d.)

#	$\mathbb{GA}$	$\hat{\mathcal{G}}$	$g_{\max}$	E	α	p_α	β	p_β	ϕ	ζ	n	$\bar{\pi}[\%]$	$s[\%]$	$s_E[\%]$	$-95[\%]$	$+95[\%]$	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
225	20 000	200	100	+	2PX	0,10	BM	0,04	T	2	270	2,53	1,57	0,10	-0,56	5,61	0,01	1,35	2,33	3,33	9,27
226	20 000	50	400	-	MIX	0,90	MM	0,10	T	4	270	2,53	1,58	0,10	-0,56	5,61	0,22	1,33	2,19	3,43	8,65
227	20 000	50	400	+	1PX	0,90	MM	0,10	T	2	270	2,53	1,54	0,09	-0,48	5,55	0,16	1,33	2,27	3,38	8,05
228	20 000	100	200	-	MIX	0,90	HM	0,10	T	2	270	2,54	1,52	0,09	-0,45	5,53	0,21	1,46	2,17	3,25	8,98
229	20 000	200	100	+	2PX	0,50	BM	0,30	T	2	270	2,55	1,03	0,06	0,52	4,58	0,69	1,79	2,34	3,22	6,11
230	20 000	400	50	-	MIX	0,90	HM	0,10	T	2	270	2,55	1,63	0,10	-0,65	5,75	0,40	1,46	2,10	3,31	15,26
231	20 000	200	100	-	MIX	0,90	MM	0,10	T	2	270	2,58	1,32	0,08	-0,01	5,18	0,44	1,67	2,29	3,24	8,42
232	20 000	200	100	+	MIX	0,30	HM	0,02	T	2	270	2,58	1,83	0,11	-1,00	6,17	0,01	1,28	2,11	3,52	12,60
233	20 000	400	50	-	MIX	0,90	MM	0,10	T	2	270	2,64	1,26	0,08	0,17	5,11	0,55	1,72	2,37	3,41	7,22
234	20 000	200	100	+	MIX	0,70	BM	0,30	T	2	270	2,65	1,15	0,07	0,39	4,90	0,69	1,78	2,41	3,37	7,99
235	20 000	50	400	-	MIX	0,90	MM	0,10	T	3	270	2,66	1,35	0,08	0,02	5,30	0,58	1,74	2,43	3,39	8,24
236	20 000	200	100	+	MIX	0,10	MM	0,04	T	2	270	2,67	1,67	0,10	-0,59	5,94	0,29	1,47	2,28	3,46	9,36
237	20 000	200	100	+	2PX	0,30	BM	0,30	T	2	270	2,68	1,12	0,07	0,49	4,88	0,75	1,84	2,53	3,35	7,33
238	20 000	100	200	-	PSX	0,90	HM	0,10	T	2	270	2,69	1,67	0,10	-0,60	5,97	0,14	1,46	2,34	3,38	9,32
239	20 000	200	100	+	MIX	0,50	BM	0,30	T	2	270	2,69	1,15	0,07	0,43	4,95	0,23	1,87	2,54	3,31	8,84
240	20 000	100	200	-	1PX	0,90	HM	0,10	T	2	270	2,71	1,61	0,10	-0,44	5,86	0,27	1,49	2,44	3,53	11,58
241	20 000	50	400	+	MIX	0,90	HM	0,10	T	2	270	2,71	1,86	0,11	-0,93	6,36	0,20	1,36	2,33	3,45	9,12
242	20 000	200	100	+	MIX	0,90	BM	0,30	T	2	270	2,72	1,16	0,07	0,43	5,00	0,50	1,85	2,46	3,38	8,76
243	20 000	200	100	+	2PX	0,10	MM	0,04	T	2	270	2,72	1,67	0,10	-0,55	5,99	0,00	1,55	2,46	3,61	8,40
244	20 000	200	100	+	2PX	0,70	MM	0,50	T	2	270	2,73	1,02	0,06	0,73	4,73	0,49	1,98	2,56	3,34	5,96
245	20 000	200	100	+	MIX	0,10	HM	0,30	T	2	270	2,74	1,49	0,09	-0,18	5,65	0,16	1,66	2,45	3,41	8,27
246	20 000	200	100	+	MIX	0,30	BM	0,30	T	2	270	2,75	1,08	0,07	0,64	4,86	0,58	1,87	2,70	3,47	6,29
247	20 000	400	50	+	PSX	0,90	BM	0,10	T	2	270	2,77	1,36	0,08	0,10	5,43	0,53	1,74	2,46	3,68	8,15
248	20 000	200	100	+	2PX	0,50	MM	0,50	T	2	270	2,78	1,07	0,06	0,69	4,87	0,76	1,99	2,62	3,45	6,12
249	20 000	100	200	-	2PX	0,90	BM	0,10	T	2	270	2,78	1,13	0,07	0,56	5,00	0,82	1,99	2,55	3,43	8,00
250	20 000	200	100	+	2PX	0,30	HM	0,02	T	2	270	2,79	1,74	0,11	-0,62	6,21	0,03	1,56	2,51	3,65	11,26
251	20 000	200	100	+	2PX	0,90	MM	0,50	T	2	270	2,80	1,16	0,07	0,52	5,08	0,90	1,94	2,62	3,43	7,38
252	20 000	200	100	-	PSX	0,90	HM	0,10	T	2	270	2,81	1,96	0,12	-1,02	6,64	0,14	1,40	2,25	3,62	9,11
253	20 000	100	200	-	1PX	0,90	MM	0,10	T	2	270	2,81	1,30	0,08	0,26	5,37	0,68	1,85	2,56	3,46	8,61
254	20 000	200	100	+	MIX	0,10	MM	0,30	T	2	270	2,82	1,30	0,08	0,26	5,37	0,58	1,89	2,62	3,52	9,08
255	20 000	200	100	+	2PX	0,10	MM	0,30	T	2	270	2,82	1,31	0,08	0,25	5,39	0,32	1,96	2,58	3,41	8,37
256	20 000	400	50	-	1PX	0,90	BM	0,10	T	2	270	2,83	1,26	0,08	0,36	5,29	0,76	1,87	2,64	3,52	8,43

Tab. C.2: Statystyki opisowe wyników algorytmu GA dla $\tilde{\Omega} = 30$ (c.d.)

#	$\tilde{G}_A$	$\tilde{\mathcal{P}}$	$g_{\max}$	E	α	p_α	β	p_β	ϕ	ζ	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
257	20 000	200	100	-	IPX	0,90	BM	0,10	T	2	270	2,85	1,33	0,08	0,23	5,46	0,46	1,90	2,56	3,35	8,32
258	20 000	200	100	+	MIX	0,50	MM	0,50	T	2	270	2,88	1,11	0,07	0,71	5,05	0,84	2,10	2,69	3,54	7,03
259	20 000	200	100	+	MIX	0,30	MM	0,50	T	2	270	2,92	1,14	0,07	0,69	5,14	0,93	2,11	2,75	3,56	7,70
260	20 000	200	100	+	2PX	0,10	HM	0,30	T	2	270	2,92	1,45	0,09	0,07	5,77	0,10	1,87	2,68	3,64	7,77
261	20 000	200	100	+	2PX	0,30	MM	0,50	T	2	270	2,93	1,15	0,07	0,68	5,18	0,95	2,09	2,74	3,62	7,33
262	20 000	200	100	+	2PX	0,10	BM	0,02	T	2	270	2,93	1,86	0,11	-0,71	6,58	0,23	1,62	2,59	3,91	12,12
263	20 000	100	200	+	UX	0,90	MM	0,10	T	2	270	2,94	1,54	0,09	-0,08	5,95	0,40	1,83	2,74	3,75	12,18
264	20 000	200	100	+	MIX	0,70	MM	0,50	T	2	270	2,94	1,24	0,08	0,50	5,38	0,97	2,09	2,64	3,60	8,42
265	20 000	100	200	-	MIX	0,90	MM	0,10	T	2	270	2,96	1,40	0,09	0,22	5,71	0,58	1,97	2,64	3,79	9,06
266	20 000	200	100	+	MIX	0,90	MM	0,50	T	2	270	2,97	1,24	0,08	0,54	5,41	0,63	2,09	2,71	3,69	7,66
267	20 000	200	100	+	MIX	0,10	HM	0,50	T	2	270	2,98	1,26	0,08	0,52	5,45	0,74	2,02	2,86	3,71	7,77
268	20 000	200	100	+	MIX	0,10	MM	0,02	T	2	270	2,99	1,84	0,11	-0,61	6,59	0,24	1,64	2,62	4,01	9,38
269	20 000	200	100	+	2PX	0,10	MM	0,02	T	2	270	2,99	1,77	0,11	-0,48	6,46	0,26	1,81	2,58	3,93	9,11
270	20 000	200	100	+	UX	0,90	MM	0,10	T	2	270	2,99	1,69	0,10	-0,32	6,31	0,25	1,83	2,65	3,71	10,60
271	20 000	400	50	-	MIX	0,90	BM	0,10	T	2	270	2,99	1,31	0,08	0,43	5,56	0,61	2,06	2,73	3,74	8,23
272	20 000	200	100	+	UX	0,90	BM	0,10	T	2	270	3,01	1,62	0,10	-0,17	6,19	0,33	1,85	2,65	3,84	10,18
273	20 000	200	100	+	MIX	0,10	BM	0,02	T	2	270	3,04	1,81	0,11	-0,50	6,59	0,00	1,74	2,69	4,21	8,29
274	20 000	200	100	+	2PX	0,10	HM	0,50	T	2	270	3,08	1,42	0,09	0,29	5,87	0,68	2,06	2,88	3,92	8,41
275	20 000	50	400	-	2PX	0,90	HM	0,10	T	2	270	3,09	1,85	0,11	-0,54	6,72	0,38	1,84	2,69	3,98	14,02
276	20 000	200	100	-	MIX	0,90	BM	0,10	T	2	270	3,11	1,36	0,08	0,45	5,77	0,77	2,19	2,85	3,68	8,34
277	20 000	100	200	+	UX	0,90	BM	0,10	T	2	270	3,13	1,68	0,10	-0,17	6,43	0,29	1,95	2,78	3,93	9,67
278	20 000	200	100	+	MIX	0,10	HM	0,10	T	2	270	3,15	1,86	0,11	-0,49	6,79	0,07	1,92	2,87	3,98	12,32
279	20 000	200	100	+	MIX	0,10	BM	0,30	T	2	270	3,16	1,39	0,08	0,44	5,88	0,77	2,25	2,82	3,78	9,04
280	20 000	200	100	+	UX	0,90	HM	0,10	T	2	270	3,20	2,00	0,12	-0,72	7,11	0,14	1,80	2,77	4,30	15,68
281	20 000	200	100	+	MIX	0,10	HM	0,08	T	2	270	3,21	2,17	0,13	-1,05	7,46	0,10	1,78	2,75	4,08	18,19
282	20 000	200	100	+	2PX	0,70	BM	0,50	T	2	270	3,21	1,19	0,07	0,87	5,55	1,03	2,36	3,05	4,00	8,69
283	20 000	50	400	-	2PX	0,90	MM	0,10	T	2	270	3,21	1,50	0,09	0,28	6,15	0,35	2,19	3,00	3,98	10,26
284	20 000	200	100	+	2PX	0,10	BM	0,30	T	2	270	3,22	1,28	0,08	0,72	5,72	0,83	2,33	3,11	3,98	8,13
285	20 000	400	50	+	UX	0,90	BM	0,10	T	2	270	3,23	1,68	0,10	-0,05	6,52	0,34	1,98	3,00	4,13	11,43
286	20 000	400	50	-	PSX	0,90	HM	0,10	T	2	270	3,24	1,94	0,12	-0,57	7,04	0,20	1,74	2,77	4,35	10,31
287	20 000	400	50	+	UX	0,90	MM	0,10	T	2	270	3,24	1,74	0,11	-0,18	6,66	0,44	1,97	2,87	4,18	9,74
288	20 000	200	100	+	2PX	0,90	BM	0,50	T	2	270	3,27	1,23	0,08	0,85	5,69	0,99	2,36	3,06	3,94	7,56

Tab. C.2: Statystyki opisowe wyników algorytmu $\mathbb{GA}$ dla $\hat{\Omega} = 30$ (c.d.)

#	$\mathbb{GA}$	$\hat{\mathcal{S}}$	$g_{\max}$	E	α	p_α	β	p_β	ϕ	ζ	n	$\bar{\pi}[\%]$	$s[\%]$	$s_E[\%]$	$-95[\%]$	$+95[\%]$	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
289	20 000	200	100	+	MIX	0,50	BM	0,50	T	2	270	3,28	1,23	0,07	0,88	5,69	1,24	2,39	3,03	4,07	8,02
290	20 000	50	400	+	IPX	0,90	HM	0,10	T	2	270	3,31	1,99	0,12	-0,60	7,22	0,11	1,84	2,93	4,50	12,16
291	20 000	50	400	-	MIX	0,90	HM	0,10	T	2	270	3,32	1,82	0,11	-0,24	6,89	0,20	2,06	2,96	4,21	11,54
292	20 000	200	100	+	2PX	0,50	BM	0,50	T	2	270	3,33	1,31	0,08	0,77	5,90	0,71	2,37	3,15	3,99	8,29
293	20 000	200	100	+	2PX	0,10	HM	0,10	T	2	270	3,38	2,01	0,12	-0,56	7,32	0,39	2,01	3,01	4,19	10,81
294	20 000	200	100	+	2PX	0,10	MM	0,50	T	2	270	3,39	1,34	0,08	0,77	6,02	1,14	2,42	3,17	4,21	9,44
295	20 000	200	100	+	MIX	0,90	BM	0,50	T	2	270	3,40	1,31	0,08	0,82	5,97	1,24	2,41	3,20	4,08	10,63
296	20 000	100	200	+	UX	0,90	HM	0,10	T	2	270	3,41	2,22	0,14	-0,95	7,76	0,16	1,82	2,95	4,30	13,51
297	20 000	200	100	+	MIX	0,10	HM	0,06	T	2	270	3,43	2,14	0,13	-0,78	7,63	0,06	1,87	2,93	4,53	12,54
298	20 000	200	100	+	MIX	0,70	BM	0,50	T	2	270	3,44	1,36	0,08	0,77	6,11	0,85	2,44	3,22	4,16	8,22
299	20 000	200	100	+	MIX	0,30	BM	0,50	T	2	270	3,46	1,30	0,08	0,90	6,01	0,85	2,45	3,32	4,28	8,10
300	20 000	200	100	+	2PX	0,30	BM	0,50	T	2	270	3,46	1,33	0,08	0,85	6,07	0,66	2,44	3,33	4,17	10,00
301	20 000	50	400	-	PSX	0,90	HM	0,10	T	2	270	3,47	1,92	0,12	-0,29	7,23	0,15	2,04	3,02	4,56	9,65
302	20 000	200	100	+	MIX	0,10	MM	0,50	T	2	270	3,47	1,48	0,09	0,57	6,37	0,44	2,47	3,28	4,29	10,67
303	20 000	400	50	+	UX	0,90	HM	0,10	T	2	270	3,47	2,12	0,13	-0,69	7,63	0,29	1,88	3,08	4,48	14,97
304	20 000	50	400	+	UX	0,90	BM	0,10	T	2	270	3,48	2,01	0,12	-0,46	7,42	0,56	1,97	3,15	4,55	12,35
305	20 000	200	100	+	2PX	0,10	HM	0,08	T	2	270	3,51	1,96	0,12	-0,33	7,35	0,32	1,98	3,15	4,58	9,14
306	20 000	50	400	+	UX	0,90	MM	0,10	T	2	270	3,51	1,95	0,12	-0,31	7,33	0,26	2,07	3,25	4,59	10,91
307	20 000	100	200	-	IPX	0,90	BM	0,10	T	2	270	3,52	1,52	0,09	0,53	6,51	0,85	2,42	3,23	4,35	10,21
308	20 000	200	100	+	2PX	0,10	HM	0,06	T	2	270	3,61	2,22	0,14	-0,74	7,96	0,13	2,09	3,13	4,78	13,84
309	20 000	100	200	-	MIX	0,90	BM	0,10	T	2	270	3,62	1,44	0,09	0,80	6,44	1,12	2,57	3,44	4,44	9,43
310	20 000	200	100	+	MIX	0,10	HM	0,04	T	2	270	3,64	2,34	0,14	-0,95	8,22	0,14	1,97	3,16	4,69	13,90
311	20 000	200	100	+	MIX	0,10	BM	0,50	T	2	270	3,76	1,45	0,09	0,93	6,60	0,82	2,75	3,52	4,65	8,01
312	20 000	200	100	+	2PX	0,10	HM	0,04	T	2	270	3,78	2,10	0,13	-0,35	7,91	0,16	2,24	3,41	4,94	9,53
313	20 000	50	400	+	UX	0,90	HM	0,10	T	2	270	3,78	2,21	0,13	-0,55	8,11	0,01	2,31	3,37	4,73	14,86
314	20 000	200	100	+	2PX	0,10	BM	0,50	T	2	270	3,79	1,46	0,09	0,93	6,65	0,90	2,71	3,58	4,72	11,03
315	20 000	50	400	-	IPX	0,90	HM	0,10	T	2	270	3,87	1,89	0,12	0,16	7,57	0,39	2,52	3,61	4,85	11,30
316	20 000	50	400	-	IPX	0,90	MM	0,10	T	2	270	3,87	1,68	0,10	0,57	7,17	0,85	2,72	3,51	4,84	11,17
317	20 000	50	400	-	2PX	0,90	BM	0,10	T	2	270	3,90	1,57	0,10	0,83	6,97	0,95	2,84	3,63	4,66	10,49
318	20 000	400	50	-	UX	0,90	MM	0,10	T	2	270	3,92	2,01	0,12	-0,01	7,86	0,85	2,48	3,48	4,91	15,16
319	20 000	50	400	-	MIX	0,90	MM	0,10	T	2	270	3,97	1,68	0,10	0,69	7,26	0,72	2,69	3,80	4,96	8,79
320	20 000	200	100	-	UX	0,90	MM	0,10	T	2	270	3,98	2,02	0,12	0,02	7,94	0,96	2,49	3,52	4,91	14,69

Tab. C.2: Statystyki opisowe wyników algorytmu $\mathbb{GA}$ dla $\tilde{\Omega} = 30$ (c.d.)

#	$\mathbb{GA}$	$\tilde{\mathcal{P}}$	$g_{\max}$	E	α	p_{α}	β	p_{β}	ϕ	ζ	n	$\overline{x}[\%]$	$s[\%]$	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
321	20 000	200	100	-	UX	0,90	HM	0,10	T	2	270	4,10	2,51	0,15	-0,82	9,02	0,61	2,41	3,65	5,15	25,94
322	20 000	400	50	-	UX	0,90	HM	0,10	T	2	270	4,10	2,29	0,14	-0,39	8,59	0,49	2,45	3,60	5,35	15,31
323	20 000	400	50	-	UX	0,90	BM	0,10	T	2	270	4,18	1,97	0,12	0,32	8,04	0,89	2,67	3,84	5,31	13,20
324	20 000	200	100	+	2PX	0,10	HM	0,02	T	2	270	4,26	2,13	0,13	0,08	8,43	0,38	2,60	4,14	5,49	11,79
325	20 000	200	100	+	MIX	0,10	HM	0,02	T	2	270	4,29	2,46	0,15	-0,52	9,10	0,49	2,55	3,89	5,60	20,71
326	20 000	200	100	-	UX	0,90	BM	0,10	T	2	270	4,42	1,97	0,12	0,56	8,27	0,84	2,99	4,12	5,49	12,85
327	20 000	50	400	-	MIX	0,90	BM	0,10	T	2	270	4,64	1,84	0,11	1,04	8,24	1,35	3,25	4,53	5,51	12,30
328	20 000	50	400	-	1PX	0,90	BM	0,10	T	2	270	4,69	2,07	0,13	0,63	8,75	1,30	3,25	4,35	5,61	14,78
329	20 000	100	200	-	UX	0,90	HM	0,10	T	2	270	4,72	2,72	0,17	-0,61	10,06	0,81	2,82	4,28	5,96	25,52
330	20 000	400	50	-	PSX	0,90	MM	0,10	T	2	270	4,79	2,49	0,15	-0,09	9,67	0,67	2,86	4,28	6,32	13,82
331	20 000	100	200	-	UX	0,90	MM	0,10	T	2	270	4,81	2,29	0,14	0,32	9,29	1,28	3,18	4,39	6,09	14,73
332	20 000	200	100	-	PSX	0,90	MM	0,10	T	2	270	4,92	2,69	0,16	-0,36	10,20	0,77	2,87	4,33	6,20	14,65
333	20 000	200	100	-	2PX	0,90	MM	0,50	T	2	270	4,98	1,77	0,11	1,51	8,45	1,01	3,72	4,69	6,18	10,83
334	20 000	100	200	-	PSX	0,90	MM	0,10	T	2	270	5,13	2,60	0,16	0,03	10,23	0,40	3,17	4,63	6,87	13,03
335	20 000	100	200	-	UX	0,90	BM	0,10	T	2	270	5,19	2,17	0,13	0,93	9,44	1,43	3,57	4,84	6,34	13,52
336	20 000	50	400	-	UX	0,90	HM	0,10	T	2	270	5,54	3,06	0,19	-0,46	11,54	1,40	3,39	4,90	6,95	26,65
337	20 000	400	50	-	PSX	0,90	BM	0,10	T	2	270	5,66	2,64	0,16	0,49	10,83	1,10	3,61	5,23	7,23	14,52
338	20 000	50	400	-	PSX	0,90	MM	0,10	T	2	270	6,10	2,94	0,18	0,33	11,87	1,20	3,95	5,42	7,85	16,64
339	20 000	50	400	-	UX	0,90	MM	0,10	T	2	270	6,11	2,54	0,15	1,13	11,09	1,67	4,29	5,67	7,48	15,05
340	20 000	200	100	-	PSX	0,90	BM	0,10	T	2	270	6,28	2,92	0,18	0,56	12,00	1,50	3,93	5,72	8,31	15,04
341	20 000	100	200	-	PSX	0,90	BM	0,10	T	2	270	6,79	3,04	0,18	0,83	12,74	0,74	4,58	6,27	8,67	16,60
342	20 000	50	400	-	UX	0,90	BM	0,10	T	2	270	6,92	2,85	0,17	1,33	12,52	1,80	4,74	6,65	8,39	19,21
343	20 000	50	400	-	PSX	0,90	BM	0,10	T	2	270	8,28	3,30	0,20	1,82	14,75	1,40	5,92	7,57	10,47	19,09

Tab. C.3: Statystyki opisowe wyników algorytmu T $\mathcal{S}$ dla $\tilde{\Omega} = 30$

#	T $\mathcal{S}$	β	$S_{\max}$	M_n	M_p	$T_{\max}$	n	$\overline{\mathcal{A}}[\%]$	$s[\%]$	$s_E[\%]$	$-95[\%]$	$+95[\%]$	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
1	20 000	MM	10	100	10	5	270	5,23	2,36	0,14	0,61	9,84	0,49	3,48	4,88	6,72	15,24
2	20 000	MM	10	50	10	5	270	5,25	2,46	0,15	0,44	10,07	0,85	3,54	4,90	6,79	12,75
3	20 000	MM	10	10	10	5	270	5,32	2,49	0,15	0,43	10,21	0,79	3,52	4,99	6,93	14,03
4	20 000	MM	20	50	50	5	270	5,45	2,50	0,15	0,55	10,35	0,77	3,61	5,13	7,00	14,59
5	20 000	MM	20	100	50	5	270	5,45	2,44	0,15	0,67	10,23	0,20	3,67	5,04	6,91	14,06
6	20 000	MM	20	50	100	5	270	5,51	2,54	0,15	0,53	10,49	0,46	3,53	5,19	7,33	14,55
7	20 000	MM	20	10	10	5	270	5,54	2,61	0,16	0,43	10,66	0,29	3,58	5,16	7,18	13,99
8	20 000	MM	20	50	10	5	270	5,56	2,46	0,15	0,74	10,38	0,74	3,75	5,25	7,08	14,27
9	20 000	MM	20	10	100	5	270	5,57	2,49	0,15	0,68	10,45	0,75	3,79	5,33	7,19	13,81
10	20 000	MM	20	100	10	5	270	5,60	2,52	0,15	0,66	10,54	0,91	3,60	5,27	7,48	13,79
11	20 000	MM	20	100	100	5	270	5,62	2,54	0,15	0,64	10,61	0,25	3,75	5,32	7,26	13,80
12	20 000	BM	40	100	10	5	270	5,65	2,35	0,14	1,04	10,26	0,34	4,04	5,45	7,41	12,18
13	20 000	BM	40	50	100	5	270	5,65	2,43	0,15	0,88	10,41	0,57	3,74	5,30	7,08	13,98
14	20 000	MM	40	10	50	5	270	5,65	2,42	0,15	0,92	10,39	0,97	3,79	5,38	7,44	12,34
15	20 000	MM	25	10	10	6	270	5,67	2,59	0,16	0,59	10,74	0,71	3,71	5,49	7,48	13,66
16	20 000	BM	10	50	10	5	270	5,67	2,51	0,15	0,75	10,58	0,40	3,92	5,45	7,27	14,69
17	20 000	MM	20	10	50	5	270	5,68	2,53	0,15	0,73	10,64	0,54	3,82	5,32	7,32	13,99
18	20 000	MM	50	10	10	3	270	5,70	2,53	0,15	0,75	10,65	0,65	3,98	5,34	7,25	14,08
19	20 000	MM	50	10	10	6	270	5,72	2,63	0,16	0,57	10,88	0,10	3,86	5,34	7,24	13,99
20	20 000	BM	10	10	10	5	270	5,73	2,58	0,16	0,68	10,78	0,50	3,85	5,32	7,41	13,07
21	20 000	MM	40	10	100	5	270	5,74	2,64	0,16	0,56	10,91	0,63	3,81	5,53	7,27	14,95
22	20 000	BM	25	10	10	9	270	5,74	2,41	0,15	1,01	10,47	0,34	3,97	5,74	7,22	12,78
23	20 000	MM	25	10	10	9	270	5,74	2,55	0,16	0,73	10,75	0,66	3,85	5,53	7,26	14,19
24	20 000	BM	40	100	50	5	270	5,75	2,57	0,16	0,70	10,79	0,07	3,85	5,43	7,37	15,21
25	20 000	BM	40	10	100	5	270	5,75	2,55	0,16	0,75	10,76	0,57	3,76	5,51	7,42	13,72
26	20 000	MM	40	50	100	5	270	5,76	2,62	0,16	0,64	10,89	0,41	3,90	5,35	7,44	15,13
27	20 000	MM	25	10	10	3	270	5,77	2,63	0,16	0,61	10,92	0,33	3,84	5,49	7,34	14,92
28	20 000	MM	40	100	50	5	270	5,78	2,62	0,16	0,66	10,91	0,45	3,77	5,48	7,71	13,72
29	20 000	BM	20	100	100	5	270	5,79	2,43	0,15	1,03	10,55	0,52	3,95	5,58	7,26	12,30
30	20 000	BM	10	100	10	5	270	5,79	2,41	0,15	1,06	10,52	0,88	3,98	5,45	7,50	12,45
31	20 000	MM	40	10	10	5	270	5,80	2,65	0,16	0,60	11,00	0,71	3,81	5,51	7,31	15,39
32	20 000	BM	40	100	100	5	270	5,82	2,58	0,16	0,77	10,86	0,38	3,94	5,64	7,52	14,59

Tab. C.3: Statystyki opisowe wyników algorytmu T $\hat{S}$ dla $\hat{\Omega} = 30$ (c.d.)

#	T $\hat{S}$	β	$S_{\max}$	M_m	M_p	$T_{\max}$	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
33	20 000	BM	40	10	50	5	270	5,83	2,64	0,16	0,65	11,01	0,59	3,71	5,69	7,67	14,11
34	20 000	BM	40	50	50	5	270	5,83	2,51	0,15	0,92	10,75	0,75	4,05	5,34	7,61	14,40
35	20 000	MM	40	100	100	5	270	5,84	2,66	0,16	0,61	11,06	0,71	3,95	5,65	7,51	14,23
36	20 000	MM	50	10	10	9	270	5,85	2,72	0,17	0,52	11,17	0,27	3,91	5,48	7,68	15,03
37	20 000	BM	20	100	50	5	270	5,85	2,53	0,15	0,89	10,80	0,64	3,98	5,37	7,39	13,57
38	20 000	MM	40	50	10	5	270	5,85	2,72	0,17	0,52	11,18	0,38	3,92	5,43	7,62	14,59
39	20 000	BM	25	10	10	6	270	5,86	2,49	0,15	0,98	10,74	0,67	4,10	5,59	7,31	14,45
40	20 000	BM	20	50	100	5	270	5,88	2,44	0,15	1,10	10,65	1,32	4,20	5,61	7,29	14,00
41	20 000	BM	20	100	10	5	270	5,88	2,53	0,15	0,93	10,84	1,12	4,04	5,48	7,41	13,06
42	20 000	MM	40	50	50	5	270	5,88	2,78	0,17	0,43	11,34	0,53	3,87	5,65	7,69	15,03
43	20 000	BM	20	10	50	5	270	5,90	2,47	0,15	1,06	10,73	1,27	4,11	5,71	7,61	13,63
44	20 000	MM	40	100	10	5	270	5,91	2,78	0,17	0,46	11,36	0,79	3,81	5,56	7,86	14,37
45	20 000	BM	40	50	10	5	270	5,91	2,60	0,16	0,81	11,00	0,91	3,98	5,52	7,68	14,52
46	20 000	BM	20	50	10	5	270	5,92	2,55	0,15	0,93	10,90	0,79	4,10	5,67	7,64	14,48
47	20 000	BM	20	50	50	5	270	5,92	2,59	0,16	0,84	11,00	1,14	3,94	5,49	7,51	14,33
48	20 000	BM	20	10	10	5	270	5,97	2,50	0,15	1,07	10,86	0,93	4,17	5,70	7,77	13,48
49	20 000	BM	20	10	100	5	270	5,97	2,62	0,16	0,83	11,11	0,44	4,03	5,76	7,65	14,12
50	20 000	BM	40	10	10	5	270	5,98	2,40	0,15	1,28	10,69	0,92	4,19	5,87	7,62	13,58
51	20 000	BM	25	10	10	3	270	6,10	2,51	0,15	1,18	11,02	1,06	4,37	5,70	7,96	13,14
52	20 000	MM	100	10	10	9	270	6,15	2,73	0,17	0,79	11,51	0,91	4,13	5,81	7,75	14,58
53	20 000	BM	50	10	10	3	270	6,18	2,44	0,15	1,40	10,96	1,28	4,30	5,84	7,95	15,55
54	20 000	MM	100	10	10	6	270	6,21	2,94	0,18	0,45	11,98	0,32	4,01	5,81	8,08	16,19
55	20 000	BM	50	10	10	6	270	6,23	2,53	0,15	1,28	11,19	0,92	4,44	5,84	7,88	14,78
56	20 000	BM	100	10	10	3	270	6,24	2,71	0,16	0,94	11,55	0,27	4,26	5,85	7,88	16,04
57	20 000	BM	50	10	10	9	270	6,25	2,54	0,15	1,28	11,22	1,05	4,41	6,00	7,81	15,66
58	20 000	BM	100	10	10	9	270	6,34	2,59	0,16	1,27	11,41	1,03	4,42	5,93	8,21	13,50
59	20 000	BM	100	10	10	6	270	6,35	2,67	0,16	1,12	11,58	0,81	4,33	6,07	8,27	15,16
60	20 000	MM	100	10	10	3	270	6,36	2,96	0,18	0,55	12,16	0,71	4,20	5,93	8,17	15,74
61	20 000	HM	10	10	10	5	270	7,88	3,83	0,23	0,37	15,39	0,38	5,24	7,16	9,73	32,37
62	20 000	HM	20	50	100	5	270	7,91	3,34	0,20	1,35	14,46	0,59	5,38	7,58	9,73	17,69
63	20 000	HM	10	100	10	5	270	8,03	3,73	0,23	0,71	15,36	0,33	5,24	7,62	10,28	21,27
64	20 000	HM	20	100	100	5	270	8,16	3,87	0,24	0,58	15,74	0,28	5,31	7,55	10,73	22,67

Tab. C.3: Statystyki opisowe wyników algorytmu T $\bar{S}$ dla $\bar{\Omega} = 30$ (c.d.)

#	T $\bar{S}$	β	$S_{\max}$	M_n	M_p	$T_{\max}$	n	$\bar{\pi}[\%]$	$s[\%]$	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
65	20 000	HIM	20	100	50	5	270	8,16	3,81	0,23	0,69	15,64	0,87	5,45	7,88	10,21	22,98
66	20 000	HIM	20	10	50	5	270	8,18	3,31	0,20	1,70	14,66	0,88	5,59	8,09	10,33	18,86
67	20 000	HIM	10	50	10	5	270	8,22	3,80	0,23	0,78	15,66	0,98	5,43	7,92	10,64	22,89
68	20 000	HIM	20	10	100	5	270	8,31	3,91	0,24	0,66	15,97	0,52	5,44	8,04	10,48	22,10
69	20 000	HIM	20	50	50	5	270	8,42	4,04	0,25	0,51	16,34	0,45	5,53	7,60	10,81	23,52
70	20 000	HIM	25	10	10	6	270	8,43	4,00	0,24	0,59	16,26	0,46	5,71	7,79	10,77	25,92
71	20 000	HIM	25	10	10	9	270	8,48	3,86	0,23	0,92	16,03	0,88	5,74	8,11	10,59	29,57
72	20 000	HIM	40	10	100	5	270	8,66	4,00	0,24	0,82	16,51	0,48	5,71	8,27	10,73	22,48
73	20 000	HIM	20	50	10	5	270	8,76	4,00	0,24	0,92	16,60	1,64	5,77	8,36	11,12	22,67
74	20 000	HIM	40	100	50	5	270	8,83	3,84	0,23	1,31	16,36	0,52	5,96	8,28	11,24	20,61
75	20 000	HIM	20	10	10	5	270	8,84	3,89	0,24	1,21	16,46	0,49	5,67	8,46	11,23	22,23
76	20 000	HIM	25	10	10	3	270	8,92	4,09	0,25	0,91	16,93	1,84	5,86	8,07	11,60	22,62
77	20 000	HIM	40	10	50	5	270	8,96	3,91	0,24	1,30	16,62	1,16	6,01	8,44	11,44	25,01
78	20 000	HIM	20	100	10	5	270	8,99	4,03	0,25	1,09	16,89	1,32	6,09	8,54	11,53	24,31
79	20 000	HIM	40	50	100	5	270	9,07	3,81	0,23	1,59	16,55	0,90	6,49	8,61	11,25	21,27
80	20 000	HIM	40	50	50	5	270	9,10	3,81	0,23	1,63	16,56	0,64	6,30	8,72	11,59	22,04
81	20 000	HIM	50	10	10	6	270	9,26	3,93	0,24	1,56	16,97	1,16	6,52	8,91	11,78	21,82
82	20 000	HIM	40	100	100	5	270	9,30	3,76	0,23	1,93	16,67	0,51	6,52	9,05	11,85	21,60
83	20 000	HIM	50	10	10	3	270	9,34	4,07	0,25	1,36	17,31	1,16	6,07	8,97	12,06	20,99
84	20 000	HIM	50	10	10	9	270	9,36	4,33	0,26	0,87	17,86	0,90	5,94	8,82	12,32	25,55
85	20 000	HIM	40	50	10	5	270	9,78	4,32	0,26	1,32	18,25	1,53	6,58	9,24	12,38	27,50
86	20 000	HIM	40	100	10	5	270	10,03	4,03	0,25	2,13	17,94	2,11	7,21	9,45	12,48	26,30
87	20 000	HIM	100	10	10	3	270	10,07	4,21	0,26	1,82	18,31	1,55	7,05	9,81	12,71	24,30
88	20 000	HIM	100	10	10	6	270	10,15	4,20	0,26	1,91	18,39	2,23	7,07	9,85	12,95	23,97
89	20 000	HIM	40	10	10	5	270	10,37	4,41	0,27	1,73	19,01	1,81	7,00	9,83	13,49	28,54
90	20 000	HIM	100	10	10	9	270	10,54	4,76	0,29	1,21	19,88	0,66	7,36	9,98	13,53	32,85

Tab. C.4: Statystyki opisowe wyników algorytmu $\mathbb{H}\mathbb{A}$ dla $\tilde{\Omega} = 30$. Dla poprawy czytelności zestawienia pominięto parametry $\mathbb{G}\mathbb{A}$ i $\mathbb{S}\mathbb{A}$, których wartości nie ulegały zmianie we wszystkich eksperymentach. W przypadku pierwszego etapu realizowanego poprzez $\mathbb{G}\mathbb{A}$: $\beta = \mathbb{MM}$, $p_\beta = 0,10$, $p_\alpha = 0,90$, $E = 1$ oraz dla drugiego etapu $\mathbb{S}\mathbb{A}$: $p_p = 0,90$, $p_m = 0,02$, $h = 0$.

#	$\mathbb{G}\mathbb{A}$	$\mathbb{S}\mathbb{A}$	$\tilde{\mathcal{P}}$	$g_{\max}$	$\alpha_{\mathbb{G}\mathbb{A}}$	$\beta_{\mathbb{S}\mathbb{A}}$	C	S	N	$\Delta_{\max}$	n	$\overline{\kappa}[\%]$	$s[\%]$	$s_E[\%]$	$-95[\%]$	$+95[\%]$	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
1	5 000	15 000	200	25	2PX	BM	2	3	1814	0,01	270	0,34	0,48	0,03	-0,60	1,27	0,00	0,03	0,16	0,44	2,70
2	10 000	10 000	250	40	2PX	BM	2	3	1210	0,01	270	0,36	0,49	0,03	-0,59	1,32	0,00	0,07	0,22	0,45	3,07
3	5 000	15 000	250	20	2PX	BM	2	3	1814	0,01	270	0,36	0,52	0,03	-0,65	1,38	0,00	0,04	0,17	0,49	3,49
4	5 000	15 000	500	10	MIX	BM	2	3	1814	0,01	270	0,37	0,50	0,03	-0,61	1,35	0,00	0,04	0,21	0,51	2,98
5	10 000	10 000	200	50	2PX	BM	2	3	1210	0,01	270	0,37	0,48	0,03	-0,57	1,31	0,00	0,06	0,21	0,45	3,01
6	10 000	10 000	250	40	2PX	BM	1	3	2419	0,01	270	0,38	0,53	0,03	-0,66	1,41	0,00	0,04	0,20	0,53	3,71
7	10 000	10 000	200	50	2PX	BM	1	3	2419	0,01	270	0,38	0,49	0,03	-0,57	1,33	0,00	0,04	0,21	0,54	2,87
8	10 000	10 000	500	20	2PX	BM	2	3	1210	0,01	270	0,39	0,44	0,03	-0,48	1,25	0,00	0,08	0,24	0,54	2,79
9	5 000	15 000	100	50	2PX	BM	2	3	1814	0,01	270	0,39	0,56	0,03	-0,70	1,48	0,00	0,03	0,18	0,45	2,89
10	5 000	15 000	200	25	MIX	BM	2	3	1814	0,01	270	0,39	0,59	0,04	-0,77	1,55	0,00	0,04	0,19	0,48	4,02
11	5 000	15 000	200	25	2PX	BM	1	3	3628	0,01	270	0,39	0,50	0,03	-0,59	1,37	0,00	0,03	0,21	0,53	2,65
12	5 000	15 000	500	10	2PX	BM	2	3	1814	0,01	270	0,39	0,53	0,03	-0,66	1,44	0,00	0,05	0,20	0,49	3,56
13	10 000	10 000	500	20	2PX	BM	1	3	2419	0,01	270	0,40	0,49	0,03	-0,57	1,37	0,00	0,06	0,23	0,57	2,65
14	5 000	15 000	100	50	MIX	BM	2	3	1814	0,01	270	0,40	0,63	0,04	-0,84	1,65	0,00	0,03	0,18	0,49	4,42
15	5 000	15 000	250	20	MIX	BM	2	3	1814	0,01	270	0,41	0,61	0,04	-0,78	1,61	0,00	0,04	0,21	0,52	4,22
16	5 000	15 000	250	20	2PX	BM	1	3	3628	0,01	270	0,41	0,58	0,04	-0,73	1,56	0,00	0,05	0,22	0,58	3,71
17	5 000	15 000	250	20	MIX	BM	1	3	3628	0,01	270	0,42	0,60	0,04	-0,76	1,59	0,00	0,02	0,18	0,58	3,95
18	5 000	15 000	100	50	2PX	BM	1	3	3628	0,01	270	0,42	0,59	0,04	-0,73	1,57	0,00	0,04	0,19	0,54	3,17
19	5 000	15 000	50	100	2PX	BM	2	3	1814	0,01	270	0,42	0,66	0,04	-0,87	1,72	0,00	0,03	0,17	0,54	4,50
20	10 000	10 000	100	100	2PX	BM	2	3	1210	0,01	270	0,43	0,60	0,04	-0,75	1,61	0,00	0,08	0,24	0,52	5,01
21	5 000	15 000	100	50	MIX	BM	1	3	3628	0,01	270	0,43	0,57	0,03	-0,69	1,55	0,00	0,05	0,21	0,59	3,05
22	5 000	15 000	50	100	2PX	BM	1	3	3628	0,01	270	0,44	0,66	0,04	-0,86	1,74	0,00	0,03	0,18	0,58	4,11
23	5 000	15 000	50	100	MIX	BM	2	3	1814	0,01	270	0,44	0,71	0,04	-0,95	1,84	0,00	0,04	0,18	0,51	5,26
24	10 000	10 000	50	200	2PX	BM	1	3	2419	0,01	270	0,45	0,58	0,04	-0,68	1,58	0,00	0,07	0,26	0,56	3,40
25	5 000	15 000	500	10	2PX	BM	1	3	3628	0,01	270	0,45	0,66	0,04	-0,84	1,74	0,00	0,04	0,21	0,59	3,92
26	5 000	15 000	500	10	MIX	BM	1	3	3628	0,01	270	0,45	0,61	0,04	-0,75	1,66	0,00	0,04	0,21	0,59	3,07
27	10 000	10 000	200	50	2PX	BM	2	5	494	0,01	270	0,45	0,52	0,03	-0,57	1,47	0,00	0,07	0,29	0,65	2,87
28	5 000	15 000	200	25	MIX	BM	1	3	3628	0,01	270	0,45	0,59	0,04	-0,70	1,61	0,00	0,03	0,21	0,68	3,54
29	5 000	15 000	50	100	MIX	BM	1	3	3628	0,01	270	0,45	0,66	0,04	-0,84	1,75	0,00	0,04	0,22	0,59	4,66
30	10 000	10 000	200	50	MIX	BM	2	3	1210	0,01	270	0,45	0,57	0,03	-0,66	1,57	0,00	0,07	0,25	0,56	3,05

Tab. C.4: Statystyki opisowe wyników algorytmu HIA dla $\hat{\Omega} = 30$ (c.d.)

#	G _A	S _A	$\hat{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	n	$\bar{x}[\%]$	s[%]	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
31	10 000	10 000	100	100	2PX	BM	1	3	2419	0,01	270	0,46	0,64	0,04	-0,80	1,71	0,00	0,07	0,27	0,56	5,22
32	10 000	10 000	50	200	2PX	BM	2	3	1210	0,01	270	0,46	0,64	0,04	-0,80	1,71	0,00	0,07	0,23	0,54	3,62
33	10 000	10 000	100	100	MIX	BM	2	3	1210	0,01	270	0,46	0,61	0,04	-0,74	1,66	0,00	0,07	0,25	0,57	3,61
34	10 000	10 000	100	100	MIX	BM	1	3	2419	0,01	270	0,46	0,64	0,04	-0,80	1,72	0,00	0,04	0,22	0,59	4,00
35	10 000	10 000	250	40	2PX	BM	2	5	494	0,01	270	0,46	0,55	0,03	-0,61	1,53	0,00	0,09	0,29	0,65	3,56
36	5 000	15 000	200	25	2PX	BM	2	5	741	0,01	270	0,46	0,58	0,04	-0,68	1,60	0,00	0,08	0,27	0,62	4,21
37	15 000	5 000	200	75	2PX	BM	2	3	605	0,01	270	0,46	0,53	0,03	-0,57	1,50	0,00	0,12	0,31	0,56	2,93
38	15 000	5 000	500	30	2PX	BM	2	3	605	0,01	270	0,47	0,49	0,03	-0,48	1,42	0,00	0,12	0,33	0,67	3,67
39	10 000	10 000	50	200	MIX	BM	2	3	1210	0,01	270	0,47	0,62	0,04	-0,74	1,68	0,00	0,08	0,25	0,56	3,12
40	10 000	10 000	200	50	MIX	BM	1	3	2419	0,01	270	0,47	0,60	0,04	-0,71	1,65	0,00	0,09	0,28	0,58	3,69
41	10 000	10 000	250	40	MIX	BM	1	3	2419	0,01	270	0,47	0,55	0,03	-0,61	1,56	0,00	0,09	0,32	0,63	2,87
42	5 000	15 000	100	50	2PX	BM	2	5	741	0,01	270	0,48	0,58	0,04	-0,66	1,61	0,00	0,07	0,29	0,60	3,13
43	10 000	10 000	200	50	2PX	BM	1	5	988	0,01	270	0,48	0,52	0,03	-0,54	1,50	0,00	0,10	0,33	0,68	3,01
44	10 000	10 000	500	20	MIX	BM	2	3	1210	0,01	270	0,48	0,61	0,04	-0,71	1,67	0,00	0,09	0,29	0,63	3,70
45	15 000	5 000	500	30	2PX	BM	2	5	248	0,01	270	0,48	0,49	0,03	-0,48	1,44	0,00	0,15	0,35	0,70	4,07
46	15 000	5 000	500	30	2PX	BM	1	3	1210	0,01	270	0,48	0,50	0,03	-0,49	1,46	0,00	0,15	0,36	0,67	4,13
47	10 000	10 000	500	20	2PX	BM	2	5	494	0,01	270	0,48	0,51	0,03	-0,52	1,49	0,00	0,11	0,34	0,71	2,72
48	5 000	15 000	25	200	MIX	BM	2	3	1814	0,01	270	0,49	0,79	0,05	-1,06	2,03	0,00	0,05	0,21	0,53	5,54
49	15 000	5 000	200	75	2PX	BM	1	3	1210	0,01	270	0,49	0,52	0,03	-0,54	1,51	0,00	0,14	0,35	0,67	3,09
50	10 000	10 000	250	40	MIX	BM	2	3	1210	0,01	270	0,49	0,62	0,04	-0,72	1,69	0,00	0,09	0,26	0,59	3,12
51	5 000	15 000	25	200	2PX	BM	2	3	1814	0,01	270	0,49	0,68	0,04	-0,84	1,81	0,00	0,07	0,23	0,61	5,06
52	15 000	5 000	250	60	2PX	BM	1	3	1210	0,01	270	0,49	0,55	0,03	-0,59	1,57	0,00	0,13	0,35	0,64	4,08
53	5 000	15 000	200	25	2PX	BM	1	5	1480	0,01	270	0,49	0,54	0,03	-0,56	1,55	0,00	0,11	0,33	0,72	3,39
54	15 000	5 000	250	60	2PX	BM	2	3	605	0,01	270	0,50	0,53	0,03	-0,55	1,54	0,00	0,14	0,37	0,66	4,06
55	15 000	5 000	250	60	2PX	BM	2	5	248	0,01	270	0,50	0,56	0,03	-0,60	1,61	0,00	0,11	0,35	0,68	3,26
56	15 000	5 000	50	300	2PX	BM	1	3	1210	0,01	270	0,51	0,56	0,03	-0,58	1,59	0,00	0,12	0,35	0,63	3,57
57	5 000	15 000	250	20	2PX	BM	2	5	741	0,01	270	0,51	0,56	0,03	-0,58	1,60	0,00	0,12	0,35	0,71	3,33
58	15 000	5 000	200	75	2PX	BM	2	5	248	0,01	270	0,51	0,56	0,03	-0,59	1,62	0,00	0,12	0,32	0,74	3,22
59	10 000	10 000	25	400	MIX	BM	1	3	2419	0,01	270	0,51	0,70	0,04	-0,85	1,88	0,00	0,05	0,25	0,69	4,03
60	10 000	10 000	100	100	2PX	BM	2	5	494	0,01	270	0,51	0,64	0,04	-0,74	1,77	0,00	0,09	0,32	0,69	4,95
61	10 000	10 000	500	20	MIX	BM	1	3	2419	0,01	270	0,51	0,63	0,04	-0,72	1,75	0,00	0,07	0,29	0,73	3,59
62	10 000	10 000	25	400	2PX	BM	2	3	1210	0,01	270	0,52	0,77	0,05	-0,99	2,03	0,00	0,08	0,26	0,66	5,61

Tab. C.4: Statystyki opisowe wyników algorytmu $\mathbb{H}_A$ dla $\tilde{\Omega} = 30$ (c.d.)

#	$\tilde{G}_A$	$\tilde{S}_A$	$\tilde{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	n	$\bar{x}[\%]$	s[%]	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
63	15 000	5 000	200	75	2PX	BM	1	5	494	0,01	270	0,52	0,54	0,03	-0,55	1,59	0,00	0,17	0,37	0,73	3,41
64	5 000	15 000	250	20	MIX	BM	2	5	741	0,01	270	0,52	0,68	0,04	-0,80	1,85	0,00	0,10	0,32	0,63	4,77
65	15 000	5 000	250	60	MIX	BM	1	3	1210	0,01	270	0,52	0,59	0,04	-0,63	1,67	0,00	0,13	0,33	0,69	3,69
66	5 000	15 000	250	20	2PX	BM	1	5	1480	0,01	270	0,53	0,58	0,04	-0,61	1,66	0,00	0,11	0,35	0,74	3,49
67	5 000	15 000	100	50	2PX	BM	2	5	741	0,05	270	0,53	0,61	0,04	-0,68	1,73	0,00	0,10	0,34	0,71	3,34
68	10 000	10 000	250	40	2PX	BM	1	5	988	0,01	270	0,53	0,58	0,04	-0,62	1,67	0,00	0,15	0,41	0,70	3,99
69	15 000	5 000	100	150	2PX	BM	2	3	605	0,01	270	0,53	0,60	0,04	-0,66	1,71	0,00	0,15	0,37	0,70	5,01
70	10 000	10 000	25	400	MIX	BM	2	3	1210	0,01	270	0,53	0,69	0,04	-0,82	1,88	0,00	0,08	0,28	0,67	3,99
71	5 000	15 000	50	100	2PX	BM	2	5	741	0,05	270	0,53	0,57	0,03	-0,60	1,66	0,00	0,14	0,35	0,74	3,05
72	15 000	5 000	200	75	MIX	BM	1	3	1210	0,01	270	0,53	0,58	0,04	-0,60	1,66	0,00	0,14	0,36	0,72	3,54
73	15 000	5 000	50	300	2PX	BM	2	3	605	0,01	270	0,53	0,58	0,04	-0,60	1,67	0,00	0,15	0,35	0,70	3,39
74	5 000	15 000	100	50	2PX	BM	2	3	1814	0,05	270	0,53	0,41	0,02	-0,27	1,34	0,00	0,26	0,46	0,69	3,12
75	5 000	15 000	200	25	MIX	BM	2	5	741	0,01	270	0,53	0,66	0,04	-0,75	1,82	0,00	0,07	0,31	0,75	4,02
76	5 000	15 000	200	25	2PX	BM	2	5	741	0,05	270	0,53	0,58	0,04	-0,61	1,68	0,00	0,10	0,34	0,77	3,27
77	15 000	5 000	100	150	2PX	BM	1	3	1210	0,01	270	0,54	0,65	0,04	-0,73	1,81	0,00	0,13	0,32	0,72	5,22
78	5 000	15 000	50	100	MIX	BM	2	3	1814	0,05	270	0,54	0,43	0,03	-0,31	1,39	0,00	0,24	0,42	0,68	2,78
79	10 000	10 000	25	400	2PX	BM	1	3	2419	0,01	270	0,54	0,78	0,05	-0,98	2,07	0,00	0,08	0,31	0,70	5,55
80	10 000	10 000	500	20	2PX	BM	1	5	988	0,01	270	0,54	0,54	0,03	-0,51	1,59	0,00	0,16	0,39	0,75	2,67
81	5 000	15 000	50	100	2PX	BM	2	3	1814	0,05	270	0,54	0,43	0,03	-0,30	1,39	0,02	0,24	0,43	0,72	2,92
82	5 000	15 000	25	200	MIX	BM	1	3	3628	0,01	270	0,54	0,83	0,05	-1,09	2,18	0,00	0,05	0,26	0,68	5,69
83	5 000	15 000	250	20	MIX	BM	2	5	741	0,05	270	0,55	0,66	0,04	-0,75	1,84	0,00	0,09	0,32	0,78	3,68
84	10 000	10 000	50	200	MIX	BM	1	3	2419	0,01	270	0,55	0,66	0,04	-0,75	1,85	0,00	0,11	0,35	0,66	3,48
85	5 000	15 000	250	20	2PX	BM	2	5	741	0,05	270	0,55	0,58	0,04	-0,59	1,69	0,00	0,11	0,36	0,83	3,08
86	5 000	15 000	50	100	MIX	BM	2	5	741	0,05	270	0,55	0,67	0,04	-0,77	1,87	0,00	0,09	0,33	0,74	3,86
87	5 000	15 000	500	10	MIX	BM	2	5	741	0,05	270	0,55	0,60	0,04	-0,62	1,72	0,00	0,10	0,36	0,81	4,52
88	10 000	10 000	250	40	MIX	BM	2	5	494	0,01	270	0,55	0,61	0,04	-0,65	1,75	0,00	0,13	0,35	0,80	3,30
89	5 000	15 000	25	200	2PX	BM	1	3	3628	0,01	270	0,55	0,79	0,05	-0,99	2,10	0,00	0,05	0,22	0,65	4,69
90	5 000	15 000	200	25	MIX	BM	2	5	741	0,05	270	0,55	0,64	0,04	-0,70	1,81	0,00	0,09	0,36	0,78	3,94
91	5 000	15 000	250	20	MIX	BM	2	3	1814	0,05	270	0,56	0,47	0,03	-0,37	1,49	0,00	0,24	0,43	0,71	3,06
92	5 000	15 000	100	50	MIX	BM	2	5	741	0,01	270	0,56	0,70	0,04	-0,81	1,92	0,00	0,09	0,32	0,75	3,93
93	15 000	5 000	250	60	MIX	BM	2	3	605	0,01	270	0,56	0,59	0,04	-0,60	1,72	0,00	0,15	0,38	0,74	3,12
94	5 000	15 000	100	50	2PX	BM	1	5	1480	0,01	270	0,56	0,64	0,04	-0,69	1,81	0,00	0,15	0,35	0,71	3,41

Tab. C.4: Statystyki opisowe wyników algorytmu HIA dla $\hat{\Omega} = 30$ (c.d.)

#	$\tilde{G}\tilde{A}$	$\tilde{S}\tilde{A}$	$\tilde{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	n	$\bar{x}[\%]$	s[%]	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
95	5 000	15 000	200	25	MIX	BM	1	5	1480	0,01	270	0,56	0,65	0,04	-0,72	1,84	0,00	0,09	0,36	0,82	4,12
96	5 000	15 000	100	50	2PX	BM	3	3	1210	0,01	270	0,56	0,63	0,04	-0,67	1,80	0,00	0,12	0,39	0,81	3,59
97	15 000	5 000	100	150	2PX	BM	2	5	248	0,01	270	0,56	0,64	0,04	-0,69	1,81	0,00	0,12	0,40	0,74	5,02
98	10 000	10 000	100	100	MIX	BM	2	5	494	0,01	270	0,56	0,71	0,04	-0,82	1,95	0,00	0,13	0,35	0,73	4,20
99	5 000	15 000	200	25	2PX	BM	2	3	1814	0,05	270	0,57	0,45	0,03	-0,32	1,45	0,02	0,28	0,44	0,71	2,90
100	15 000	5 000	200	75	MIX	BM	2	3	605	0,01	270	0,57	0,61	0,04	-0,63	1,76	0,00	0,16	0,40	0,74	3,30
101	5 000	15 000	50	100	2PX	BM	3	3	1210	0,01	270	0,57	0,68	0,04	-0,77	1,91	0,00	0,13	0,39	0,75	4,79
102	10 000	10 000	100	100	2PX	BM	2	5	494	0,05	270	0,57	0,57	0,03	-0,54	1,68	0,00	0,17	0,40	0,75	2,94
103	15 000	5 000	200	75	2PX	BM	1	10	37	0,01	270	0,57	0,57	0,03	-0,54	1,69	0,00	0,19	0,40	0,80	3,33
104	10 000	10 000	100	100	2PX	BM	1	5	988	0,01	270	0,58	0,67	0,04	-0,74	1,89	0,00	0,14	0,37	0,73	5,07
105	5 000	15 000	250	20	2PX	BM	2	3	1814	0,05	270	0,58	0,49	0,03	-0,38	1,53	0,00	0,25	0,45	0,76	3,22
106	5 000	15 000	25	200	2PX	BM	2	5	741	0,05	270	0,58	0,66	0,04	-0,72	1,87	0,00	0,11	0,39	0,76	4,55
107	5 000	15 000	500	10	MIX	BM	2	3	1814	0,05	270	0,58	0,51	0,03	-0,41	1,57	0,00	0,28	0,42	0,74	3,10
108	5 000	15 000	100	50	MIX	BM	2	5	741	0,05	270	0,58	0,64	0,04	-0,67	1,82	0,00	0,12	0,40	0,78	3,19
109	5 000	15 000	25	200	MIX	BM	2	5	741	0,05	270	0,58	0,75	0,05	-0,88	2,04	0,00	0,09	0,34	0,74	5,91
110	15 000	5 000	100	150	MIX	BM	2	3	605	0,01	270	0,58	0,60	0,04	-0,60	1,75	0,00	0,17	0,39	0,73	3,10
111	15 000	5 000	500	30	MIX	BM	1	3	1210	0,01	270	0,58	0,64	0,04	-0,68	1,84	0,00	0,15	0,41	0,75	3,99
112	5 000	15 000	250	20	MIX	BM	1	5	1480	0,01	270	0,58	0,67	0,04	-0,74	1,90	0,00	0,12	0,35	0,78	4,06
113	5 000	15 000	100	50	MIX	BM	1	3	3628	0,05	270	0,58	0,48	0,03	-0,36	1,53	0,00	0,25	0,45	0,77	3,14
114	5 000	15 000	200	25	MIX	BM	1	3	3628	0,05	270	0,58	0,47	0,03	-0,35	1,51	0,00	0,27	0,47	0,75	3,11
115	10 000	10 000	250	40	MIX	BM	1	5	988	0,01	270	0,58	0,65	0,04	-0,69	1,85	0,00	0,12	0,39	0,81	3,69
116	15 000	5 000	500	30	2PX	BM	1	5	494	0,01	270	0,58	0,54	0,03	-0,47	1,64	0,00	0,20	0,46	0,82	4,15
117	5 000	15 000	25	200	2PX	BM	2	3	1814	0,05	270	0,58	0,51	0,03	-0,43	1,59	0,01	0,28	0,47	0,69	3,21
118	10 000	10 000	50	200	2PX	BM	2	5	494	0,01	270	0,59	0,71	0,04	-0,81	1,98	0,00	0,14	0,36	0,72	3,95
119	5 000	15 000	200	25	MIX	BM	2	3	1814	0,05	270	0,59	0,46	0,03	-0,32	1,49	0,00	0,27	0,45	0,81	2,71
120	5 000	15 000	500	10	2PX	BM	2	5	741	0,05	270	0,59	0,68	0,04	-0,74	1,91	0,00	0,12	0,36	0,82	3,41
121	5 000	15 000	250	20	2PX	BM	1	3	3628	0,05	270	0,59	0,53	0,03	-0,44	1,62	0,00	0,23	0,40	0,74	2,95
122	5 000	15 000	50	100	2PX	BM	1	3	3628	0,05	270	0,59	0,49	0,03	-0,38	1,55	0,00	0,27	0,44	0,77	3,08
123	15 000	5 000	250	60	2PX	BM	1	5	494	0,01	270	0,59	0,62	0,04	-0,63	1,81	0,00	0,18	0,42	0,83	4,11
124	5 000	15 000	500	10	2PX	BM	2	5	741	0,01	270	0,59	0,69	0,04	-0,77	1,95	0,00	0,12	0,35	0,78	3,59
125	5 000	15 000	500	10	MIX	BM	2	5	741	0,01	270	0,59	0,64	0,04	-0,66	1,83	0,00	0,14	0,37	0,82	3,39
126	5 000	15 000	25	200	MIX	BM	2	3	1814	0,05	270	0,59	0,56	0,03	-0,51	1,69	0,00	0,25	0,44	0,77	5,42

Tab. C.4: Statystyki opisowe wyników algorytmu $\mathbb{H}\mathbb{A}$ dla $\tilde{\Omega} = 30$ (c.d.)

#	$\tilde{G}\mathbb{A}$	$\tilde{S}\mathbb{A}$	$\tilde{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	n	$\bar{x}[\%]$	s[%]	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
127	5 000	15 000	50	100	MIX	BM	2	5	741	0,01	270	0,59	0,79	0,05	-0,95	2,13	0,00	0,09	0,34	0,74	5,32
128	5 000	15 000	100	50	MIX	BM	2	3	1814	0,05	270	0,59	0,49	0,03	-0,36	1,54	0,01	0,27	0,46	0,75	3,52
129	5 000	15 000	50	100	2PX	BM	2	5	741	0,01	270	0,59	0,81	0,05	-0,99	2,17	0,00	0,08	0,34	0,72	5,00
130	5 000	15 000	100	50	2PX	BM	5	3	727	0,01	270	0,59	0,64	0,04	-0,66	1,84	0,00	0,17	0,40	0,76	3,22
131	15 000	5 000	250	60	2PX	BM	1	10	37	0,01	270	0,59	0,64	0,04	-0,67	1,85	0,00	0,14	0,41	0,80	4,13
132	5 000	15 000	50	100	2PX	BM	4	3	908	0,01	270	0,59	0,59	0,04	-0,56	1,75	0,00	0,20	0,42	0,81	2,82
133	10 000	10 000	100	100	MIX	BM	2	5	494	0,05	270	0,60	0,60	0,04	-0,58	1,77	0,00	0,18	0,43	0,82	3,82
134	10 000	10 000	200	50	MIX	BM	2	5	494	0,01	270	0,60	0,70	0,04	-0,77	1,96	0,00	0,12	0,36	0,77	3,88
135	5 000	15 000	50	100	MIX	BM	1	3	3628	0,05	270	0,60	0,54	0,03	-0,47	1,66	0,01	0,23	0,45	0,77	3,13
136	15 000	5 000	100	150	MIX	BM	1	3	1210	0,01	270	0,60	0,67	0,04	-0,71	1,90	0,00	0,14	0,38	0,79	4,06
137	5 000	15 000	250	20	2PX	BM	3	3	1210	0,01	270	0,60	0,62	0,04	-0,62	1,81	0,00	0,16	0,38	0,85	3,44
138	5 000	15 000	200	25	2PX	BM	3	3	1210	0,01	270	0,60	0,63	0,04	-0,64	1,84	0,00	0,16	0,42	0,83	3,50
139	5 000	15 000	500	10	2PX	BM	2	3	1814	0,05	270	0,60	0,57	0,03	-0,52	1,72	0,00	0,27	0,46	0,71	3,79
140	5 000	15 000	500	10	2PX	BM	1	3	3628	0,05	270	0,60	0,62	0,04	-0,61	1,81	0,00	0,20	0,39	0,79	3,78
141	5 000	15 000	200	25	2PX	BM	5	3	727	0,01	270	0,60	0,61	0,04	-0,59	1,80	0,00	0,18	0,41	0,81	3,52
142	10 000	10 000	500	20	2PX	BM	2	5	494	0,05	270	0,60	0,60	0,04	-0,57	1,78	0,00	0,16	0,42	0,85	3,19
143	10 000	10 000	50	200	2PX	BM	2	5	494	0,05	270	0,60	0,62	0,04	-0,61	1,81	0,00	0,15	0,43	0,85	3,34
144	10 000	10 000	100	100	2PX	BM	1	3	2419	0,05	270	0,60	0,44	0,03	-0,26	1,46	0,02	0,30	0,51	0,78	2,56
145	10 000	10 000	250	40	2PX	BM	1	10	71	0,01	270	0,60	0,64	0,04	-0,65	1,86	0,00	0,17	0,43	0,80	3,97
146	5 000	15 000	50	100	MIX	BM	1	5	1480	0,01	270	0,61	0,74	0,05	-0,85	2,06	0,00	0,09	0,37	0,79	4,69
147	15 000	5 000	200	75	MIX	BM	2	5	248	0,01	270	0,61	0,62	0,04	-0,60	1,82	0,00	0,15	0,40	0,84	2,97
148	15 000	5 000	50	300	2PX	BM	2	5	248	0,01	270	0,61	0,65	0,04	-0,66	1,88	0,00	0,15	0,39	0,87	3,53
149	10 000	10 000	200	50	2PX	BM	2	5	494	0,05	270	0,61	0,58	0,04	-0,53	1,75	0,00	0,21	0,44	0,83	3,47
150	15 000	5 000	50	300	2PX	BM	1	5	494	0,01	270	0,61	0,62	0,04	-0,61	1,83	0,00	0,14	0,42	0,87	3,96
151	15 000	5 000	250	60	MIX	BM	2	5	248	0,01	270	0,61	0,64	0,04	-0,65	1,87	0,00	0,18	0,41	0,77	3,74
152	10 000	10 000	200	50	2PX	BM	1	10	71	0,01	270	0,61	0,61	0,04	-0,59	1,81	0,00	0,18	0,45	0,85	3,38
153	15 000	5 000	100	150	2PX	BM	1	5	494	0,01	270	0,61	0,67	0,04	-0,69	1,92	0,00	0,17	0,44	0,81	5,50
154	5 000	15 000	50	100	2PX	BM	1	5	1480	0,05	270	0,61	0,73	0,04	-0,82	2,04	0,00	0,13	0,37	0,76	4,50
155	15 000	5 000	50	300	MIX	BM	2	3	605	0,01	270	0,61	0,71	0,04	-0,79	2,01	0,00	0,15	0,38	0,80	4,18
156	5 000	15 000	500	10	2PX	BM	1	5	1480	0,01	270	0,61	0,69	0,04	-0,74	1,97	0,00	0,13	0,37	0,85	3,55
157	5 000	15 000	500	10	MIX	BM	1	3	3628	0,05	270	0,61	0,64	0,04	-0,63	1,86	0,00	0,21	0,41	0,74	3,44
158	5 000	15 000	250	20	2PX	BM	5	3	727	0,01	270	0,62	0,63	0,04	-0,62	1,85	0,00	0,18	0,43	0,85	3,89

Tab. C.4: Statystyki opisowe wyników algorytmu HIA dla $\hat{\Omega} = 30$ (c.d.)

#	$\tilde{G}A$	$\tilde{S}A$	$\tilde{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	n	$\bar{x}[\%]$	s[%]	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
159	10 000	10 000	100	100	MIX	BM	1	5	988	0,01	270	0,62	0,72	0,04	-0,79	2,03	0,00	0,16	0,41	0,77	4,78
160	5 000	15 000	25	200	2PX	BM	1	3	3628	0,05	270	0,62	0,61	0,04	-0,58	1,81	0,00	0,23	0,40	0,79	3,41
161	5 000	15 000	200	25	2PX	BM	1	3	3628	0,05	270	0,62	0,59	0,04	-0,55	1,78	0,00	0,23	0,42	0,77	3,24
162	5 000	15 000	100	50	2PX	BM	1	3	3628	0,05	270	0,62	0,61	0,04	-0,57	1,81	0,00	0,23	0,44	0,74	3,39
163	5 000	15 000	250	20	2PX	BM	4	3	908	0,01	270	0,62	0,63	0,04	-0,63	1,86	0,00	0,20	0,43	0,82	3,38
164	15 000	5 000	50	300	MIX	BM	1	3	1210	0,01	270	0,62	0,74	0,05	-0,84	2,08	0,00	0,16	0,39	0,80	5,87
165	15 000	5 000	500	30	2PX	BM	1	10	37	0,01	270	0,62	0,59	0,04	-0,53	1,77	0,00	0,20	0,49	0,86	4,58
166	10 000	10 000	500	20	MIX	BM	2	5	494	0,01	270	0,62	0,73	0,04	-0,81	2,05	0,00	0,15	0,37	0,76	3,86
167	10 000	10 000	50	200	MIX	BM	2	5	494	0,01	270	0,62	0,73	0,04	-0,81	2,05	0,00	0,14	0,37	0,82	4,13
168	10 000	10 000	25	400	MIX	BM	2	5	494	0,01	270	0,62	0,70	0,04	-0,75	2,00	0,00	0,15	0,37	0,83	4,05
169	5 000	15 000	250	20	MIX	BM	1	3	3628	0,05	270	0,62	0,64	0,04	-0,63	1,87	0,00	0,26	0,45	0,77	5,02
170	5 000	15 000	50	100	2PX	BM	1	5	1480	0,01	270	0,62	0,77	0,05	-0,89	2,13	0,00	0,12	0,38	0,76	5,14
171	15 000	5 000	500	30	MIX	BM	2	3	605	0,01	270	0,63	0,67	0,04	-0,69	1,94	0,00	0,19	0,45	0,80	4,32
172	10 000	10 000	50	200	2PX	BM	1	3	2419	0,05	270	0,63	0,50	0,03	-0,36	1,61	0,01	0,28	0,51	0,81	3,36
173	10 000	10 000	250	40	2PX	BM	2	5	494	0,05	270	0,63	0,58	0,04	-0,50	1,76	0,00	0,20	0,50	0,87	2,89
174	5 000	15 000	200	25	2PX	BM	4	3	908	0,01	270	0,63	0,64	0,04	-0,62	1,88	0,00	0,20	0,42	0,87	3,60
175	5 000	15 000	50	100	2PX	BM	5	3	727	0,01	270	0,63	0,67	0,04	-0,69	1,95	0,00	0,20	0,46	0,79	4,14
176	5 000	15 000	100	50	MIX	BM	1	5	1480	0,01	270	0,63	0,77	0,05	-0,89	2,15	0,00	0,08	0,37	0,90	4,43
177	15 000	5 000	250	60	MIX	BM	1	5	494	0,01	270	0,63	0,63	0,04	-0,60	1,87	0,00	0,20	0,46	0,86	3,28
178	5 000	15 000	100	50	2PX	BM	4	3	908	0,01	270	0,63	0,64	0,04	-0,62	1,89	0,00	0,18	0,45	0,83	3,61
179	10 000	10 000	100	100	2PX	BM	1	5	988	0,05	270	0,63	0,59	0,04	-0,52	1,79	0,00	0,20	0,48	0,89	4,00
180	5 000	15 000	100	50	2PX	BM	1	5	1480	0,05	270	0,64	0,65	0,04	-0,65	1,92	0,00	0,14	0,41	0,91	3,45
181	10 000	10 000	200	50	MIX	BM	1	5	988	0,01	270	0,64	0,65	0,04	-0,64	1,91	0,00	0,16	0,43	0,86	3,82
182	5 000	15 000	50	100	MIX	BM	1	5	1480	0,05	270	0,64	0,68	0,04	-0,70	1,98	0,00	0,14	0,40	0,96	4,17
183	10 000	10 000	50	200	2PX	BM	1	5	988	0,01	270	0,64	0,70	0,04	-0,74	2,02	0,00	0,15	0,45	0,85	3,81
184	10 000	10 000	250	40	2PX	BM	1	3	2419	0,05	270	0,64	0,50	0,03	-0,35	1,63	0,00	0,29	0,48	0,86	3,22
185	10 000	10 000	500	20	MIX	BM	2	5	494	0,05	270	0,64	0,60	0,04	-0,53	1,81	0,00	0,19	0,48	0,91	3,58
186	10 000	10 000	50	200	MIX	BM	1	5	988	0,01	270	0,64	0,73	0,04	-0,80	2,08	0,00	0,14	0,40	0,81	4,11
187	5 000	15 000	100	50	2PX	BM	4	5	371	0,01	270	0,64	0,65	0,04	-0,64	1,92	0,00	0,18	0,43	0,84	3,34
188	10 000	10 000	50	200	MIX	BM	2	5	494	0,05	270	0,64	0,66	0,04	-0,65	1,94	0,00	0,18	0,50	0,82	3,97
189	10 000	10 000	200	50	MIX	BM	2	5	494	0,05	270	0,64	0,65	0,04	-0,63	1,92	0,00	0,17	0,46	0,90	3,45
190	5 000	15 000	100	50	2PX	BM	5	5	297	0,01	270	0,64	0,66	0,04	-0,66	1,94	0,00	0,20	0,44	0,86	3,57

Tab. C.4: Statystyki opisowe wyników algorytmu $\mathbb{H}\mathbb{A}$ dla $\tilde{\Omega} = 30$ (c.d.)

#	$\tilde{G}\mathbb{A}$	$\tilde{S}\mathbb{A}$	$\tilde{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	n	$\bar{x}[\%]$	s[%]	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
191	10 000	10 000	200	50	2PX	BM	1	3	2419	0,05	270	0,64	0,52	0,03	-0,37	1,66	0,01	0,28	0,52	0,85	3,02
192	10 000	10 000	25	400	2PX	BM	2	5	494	0,05	270	0,65	0,69	0,04	-0,70	1,99	0,00	0,16	0,44	0,90	4,42
193	5 000	15 000	50	100	2PX	BM	5	5	297	0,01	270	0,65	0,69	0,04	-0,70	2,00	0,00	0,19	0,45	0,91	4,32
194	15 000	5 000	100	150	MIX	BM	2	5	248	0,01	270	0,65	0,65	0,04	-0,62	1,92	0,00	0,19	0,51	0,94	4,05
195	10 000	10 000	100	100	2PX	BM	2	3	1210	0,05	270	0,65	0,45	0,03	-0,23	1,53	0,00	0,32	0,56	0,91	2,67
196	10 000	10 000	100	100	MIX	BM	2	3	1210	0,05	270	0,65	0,49	0,03	-0,31	1,61	0,00	0,33	0,54	0,81	3,31
197	5 000	15 000	200	25	MIX	BM	1	5	1480	0,05	270	0,65	0,68	0,04	-0,69	1,99	0,00	0,14	0,46	0,93	3,76
198	5 000	15 000	25	200	2PX	BM	1	5	1480	0,05	270	0,65	0,80	0,05	-0,91	2,22	0,00	0,12	0,33	0,88	4,71
199	15 000	5 000	200	75	2PX	BM	2	5	248	0,05	270	0,65	0,54	0,03	-0,41	1,72	0,00	0,25	0,53	0,91	3,41
200	5 000	15 000	25	200	MIX	BM	1	3	3628	0,05	270	0,65	0,67	0,04	-0,65	1,96	0,00	0,24	0,44	0,79	5,24
201	5 000	15 000	50	100	2PX	BM	4	5	371	0,01	270	0,65	0,71	0,04	-0,73	2,04	0,00	0,18	0,45	0,87	4,37
202	5 000	15 000	250	20	2PX	BM	1	5	1480	0,05	270	0,66	0,75	0,05	-0,81	2,13	0,00	0,11	0,36	0,93	3,55
203	10 000	10 000	100	100	MIX	BM	1	3	2419	0,05	270	0,66	0,50	0,03	-0,32	1,64	0,01	0,31	0,53	0,87	3,68
204	10 000	10 000	50	200	MIX	BM	2	3	1210	0,05	270	0,66	0,46	0,03	-0,23	1,55	0,03	0,34	0,56	0,89	3,08
205	15 000	5 000	100	150	2PX	BM	2	5	248	0,05	270	0,66	0,62	0,04	-0,55	1,88	0,00	0,27	0,49	0,86	4,90
206	5 000	15 000	500	10	MIX	BM	1	5	1480	0,01	270	0,66	0,71	0,04	-0,72	2,05	0,00	0,16	0,44	0,89	3,85
207	5 000	15 000	25	200	MIX	BM	2	5	741	0,01	270	0,66	0,87	0,05	-1,03	2,36	0,00	0,14	0,40	0,80	6,35
208	15 000	5 000	200	75	2PX	BM	1	5	494	0,05	270	0,67	0,55	0,03	-0,41	1,74	0,00	0,27	0,53	0,96	3,41
209	5 000	15 000	100	50	MIX	BM	1	5	1480	0,05	270	0,67	0,74	0,05	-0,79	2,13	0,00	0,11	0,39	0,96	3,81
210	15 000	5 000	200	75	2PX	BM	1	10	37	0,05	270	0,67	0,58	0,04	-0,46	1,80	0,00	0,27	0,52	0,92	3,15
211	15 000	5 000	200	75	MIX	BM	1	5	494	0,01	270	0,67	0,65	0,04	-0,61	1,94	0,00	0,16	0,48	1,00	3,37
212	15 000	5 000	25	600	2PX	BM	2	3	605	0,01	270	0,67	0,79	0,05	-0,88	2,21	0,00	0,19	0,41	0,80	4,85
213	10 000	10 000	100	100	MIX	BM	1	5	988	0,05	270	0,67	0,63	0,04	-0,56	1,90	0,00	0,17	0,55	0,97	3,18
214	15 000	5 000	500	30	MIX	BM	2	5	248	0,01	270	0,67	0,71	0,04	-0,72	2,05	0,00	0,20	0,47	0,85	4,85
215	10 000	10 000	25	400	MIX	BM	2	3	1210	0,05	270	0,67	0,47	0,03	-0,25	1,59	0,01	0,38	0,57	0,84	3,29
216	15 000	5 000	25	600	MIX	BM	1	3	1210	0,01	270	0,67	0,73	0,04	-0,76	2,09	0,00	0,14	0,45	0,92	4,06
217	10 000	10 000	200	50	MIX	BM	1	3	2419	0,05	270	0,67	0,51	0,03	-0,33	1,66	0,04	0,32	0,54	0,86	2,85
218	10 000	10 000	250	40	2PX	BM	1	5	988	0,05	270	0,67	0,65	0,04	-0,60	1,94	0,00	0,21	0,50	0,91	4,67
219	15 000	5 000	100	150	2PX	BM	1	10	37	0,01	270	0,67	0,68	0,04	-0,67	2,01	0,00	0,20	0,44	1,01	5,26
220	10 000	10 000	200	50	MIX	BM	1	5	988	0,05	270	0,67	0,66	0,04	-0,62	1,96	0,00	0,17	0,49	0,98	3,71
221	15 000	5 000	250	60	MIX	BM	1	10	37	0,01	270	0,67	0,66	0,04	-0,62	1,97	0,00	0,20	0,50	0,89	4,27
222	10 000	10 000	25	400	MIX	BM	2	5	494	0,05	270	0,67	0,68	0,04	-0,66	2,01	0,00	0,20	0,52	0,91	4,06

Tab. C.4: Statystyki opisowe wyników algorytmu HIA dla $\hat{\Omega} = 30$ (c.d.)

#	$\tilde{G}A$	$\tilde{S}A$	$\tilde{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	n	$\bar{x}[\%]$	s[%]	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
223	10 000	10 000	25	400	2PX	BM	2	5	494	0,01	270	0,67	0,90	0,05	-1,10	2,44	0,00	0,11	0,37	0,85	5,47
224	10 000	10 000	250	40	2PX	BM	2	3	1210	0,05	270	0,67	0,48	0,03	-0,26	1,61	0,00	0,35	0,57	0,86	3,14
225	15 000	5 000	25	600	2PX	BM	1	3	1210	0,01	270	0,68	0,82	0,05	-0,92	2,27	0,00	0,14	0,36	0,89	4,89
226	10 000	10 000	100	100	2PX	BM	1	10	71	0,01	270	0,68	0,76	0,05	-0,81	2,16	0,00	0,16	0,44	0,97	5,01
227	5 000	15 000	25	200	2PX	BM	1	5	1480	0,01	270	0,68	0,79	0,05	-0,87	2,23	0,00	0,14	0,43	0,89	5,02
228	10 000	10 000	500	20	MIX	BM	1	5	988	0,01	270	0,68	0,70	0,04	-0,70	2,06	0,00	0,17	0,46	0,96	3,57
229	5 000	15 000	200	25	2PX	BM	5	5	297	0,01	270	0,68	0,66	0,04	-0,61	1,97	0,00	0,24	0,50	0,90	3,44
230	10 000	10 000	250	40	MIX	BM	2	5	494	0,05	270	0,68	0,69	0,04	-0,67	2,04	0,00	0,18	0,46	0,96	3,72
231	10 000	10 000	50	200	2PX	BM	1	5	988	0,05	270	0,68	0,72	0,04	-0,73	2,10	0,00	0,18	0,49	0,95	4,46
232	5 000	15 000	25	200	2PX	BM	2	5	741	0,01	270	0,69	0,84	0,05	-0,96	2,33	0,00	0,10	0,36	1,01	5,06
233	10 000	10 000	50	200	2PX	BM	2	3	1210	0,05	270	0,69	0,55	0,03	-0,39	1,76	0,00	0,32	0,57	0,89	4,92
234	15 000	5 000	500	30	MIX	BM	1	5	494	0,01	270	0,69	0,66	0,04	-0,60	1,98	0,00	0,21	0,52	0,92	3,52
235	10 000	10 000	250	40	MIX	BM	1	3	2419	0,05	270	0,69	0,53	0,03	-0,35	1,73	0,02	0,30	0,55	0,93	3,20
236	5 000	15 000	200	25	2PX	BM	1	5	1480	0,05	270	0,69	0,71	0,04	-0,71	2,09	0,00	0,14	0,42	1,02	3,12
237	5 000	15 000	250	20	MIX	BM	1	5	1480	0,05	270	0,69	0,78	0,05	-0,84	2,22	0,00	0,16	0,39	0,99	4,70
238	10 000	10 000	200	50	2PX	BM	2	3	1210	0,05	270	0,69	0,48	0,03	-0,26	1,64	0,02	0,38	0,58	0,90	3,25
239	5 000	15 000	500	10	2PX	BM	1	5	1480	0,05	270	0,69	0,76	0,05	-0,80	2,19	0,00	0,10	0,42	0,99	3,55
240	10 000	10 000	25	400	2PX	BM	2	3	1210	0,05	270	0,69	0,53	0,03	-0,34	1,73	0,01	0,36	0,56	0,87	3,57
241	10 000	10 000	25	400	MIX	BM	1	3	2419	0,05	270	0,70	0,62	0,04	-0,52	1,91	0,01	0,31	0,52	0,87	4,63
242	10 000	10 000	200	50	2PX	BM	1	5	988	0,05	270	0,70	0,70	0,04	-0,67	2,07	0,00	0,15	0,49	1,00	3,41
243	10 000	10 000	25	400	MIX	BM	1	5	988	0,01	270	0,70	0,77	0,05	-0,82	2,21	0,00	0,16	0,45	0,97	4,11
244	5 000	15 000	200	25	2PX	BM	1	10	106	0,01	270	0,70	0,68	0,04	-0,63	2,03	0,00	0,21	0,54	0,94	4,26
245	10 000	10 000	50	200	MIX	BM	1	3	2419	0,05	270	0,70	0,59	0,04	-0,45	1,86	0,03	0,32	0,54	0,92	4,59
246	5 000	15 000	250	20	2PX	BM	5	5	297	0,01	270	0,70	0,67	0,04	-0,62	2,02	0,00	0,26	0,49	0,95	3,95
247	15 000	5 000	25	600	MIX	BM	2	3	605	0,01	270	0,70	0,71	0,04	-0,69	2,10	0,00	0,20	0,49	0,98	4,11
248	5 000	15 000	25	200	2PX	BM	5	3	727	0,01	270	0,71	0,77	0,05	-0,81	2,22	0,00	0,19	0,46	0,87	5,36
249	5 000	15 000	250	20	2PX	BM	4	5	371	0,01	270	0,71	0,65	0,04	-0,57	1,98	0,00	0,27	0,52	0,95	4,00
250	15 000	5 000	100	150	MIX	BM	1	5	494	0,01	270	0,71	0,68	0,04	-0,63	2,05	0,00	0,23	0,52	1,03	4,21
251	15 000	5 000	200	75	MIX	BM	1	10	37	0,01	270	0,71	0,71	0,04	-0,68	2,11	0,00	0,21	0,51	0,97	3,89
252	5 000	15 000	200	25	2PX	BM	4	5	371	0,01	270	0,71	0,72	0,04	-0,69	2,11	0,00	0,20	0,50	0,97	3,77
253	5 000	15 000	100	50	2PX	BM	3	5	494	0,01	270	0,71	0,71	0,04	-0,69	2,11	0,00	0,21	0,53	0,98	4,11
254	15 000	5 000	250	60	2PX	BM	2	5	248	0,05	270	0,71	0,59	0,04	-0,45	1,88	0,00	0,31	0,60	0,94	3,29

Tab. C.4: Statystyki opisowe wyników algorytmu $\mathbb{H}\mathbb{A}$ dla $\tilde{\Omega} = 30$ (c.d.)

#	$\tilde{G}\mathbb{A}$	$\tilde{S}\mathbb{A}$	$\tilde{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	n	$\bar{x}[\%]$	s[%]	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
255	5 000	15 000	100	50	2PX	BM	1	10	106	0,01	270	0,71	0,69	0,04	-0,64	2,06	0,00	0,20	0,53	1,04	3,37
256	10 000	10 000	500	20	MIX	BM	2	3	1210	0,05	270	0,71	0,54	0,03	-0,35	1,78	0,00	0,36	0,57	0,89	3,03
257	5 000	15 000	50	100	2PX	BM	3	5	494	0,01	270	0,72	0,75	0,05	-0,74	2,18	0,00	0,23	0,51	0,91	4,17
258	15 000	5 000	50	300	MIX	BM	2	5	248	0,01	270	0,72	0,79	0,05	-0,84	2,28	0,00	0,19	0,48	0,99	5,52
259	10 000	10 000	500	20	2PX	BM	1	3	2419	0,05	270	0,72	0,60	0,04	-0,46	1,90	0,00	0,32	0,57	0,96	4,17
260	5 000	15 000	25	200	MIX	BM	1	5	1480	0,05	270	0,72	0,88	0,05	-1,00	2,44	0,00	0,12	0,43	0,97	5,22
261	10 000	10 000	25	400	2PX	BM	1	3	2419	0,05	270	0,72	0,67	0,04	-0,59	2,03	0,01	0,28	0,52	0,93	4,48
262	15 000	5 000	50	300	MIX	BM	1	5	494	0,01	270	0,72	0,82	0,05	-0,88	2,33	0,00	0,19	0,48	0,91	5,56
263	15 000	5 000	250	60	2PX	BM	1	5	494	0,05	270	0,72	0,63	0,04	-0,52	1,97	0,00	0,24	0,59	1,00	3,61
264	10 000	10 000	500	20	2PX	BM	2	3	1210	0,05	270	0,73	0,58	0,04	-0,41	1,86	0,04	0,34	0,55	0,94	3,93
265	5 000	15 000	200	25	2PX	BM	3	5	494	0,01	270	0,73	0,72	0,04	-0,68	2,13	0,00	0,20	0,51	1,00	4,39
266	5 000	15 000	500	10	MIX	BM	1	5	1480	0,05	270	0,73	0,88	0,05	-1,01	2,46	0,00	0,16	0,44	0,92	5,04
267	15 000	5 000	100	150	MIX	BM	1	10	37	0,01	270	0,73	0,72	0,04	-0,68	2,13	0,00	0,21	0,54	1,03	4,06
268	15 000	5 000	250	60	MIX	BM	2	5	248	0,05	270	0,73	0,64	0,04	-0,53	1,99	0,00	0,24	0,52	1,07	3,93
269	10 000	10 000	25	400	2PX	BM	1	5	988	0,01	270	0,73	0,89	0,05	-1,02	2,48	0,00	0,17	0,47	0,94	5,46
270	10 000	10 000	250	40	MIX	BM	2	3	1210	0,05	270	0,73	0,51	0,03	-0,28	1,74	0,00	0,38	0,60	0,94	3,22
271	10 000	10 000	50	200	MIX	BM	1	5	988	0,05	270	0,74	0,79	0,05	-0,82	2,29	0,00	0,20	0,52	0,97	6,09
272	15 000	5 000	200	75	2PX	BM	1	3	1210	0,05	270	0,74	0,53	0,03	-0,30	1,77	0,00	0,39	0,62	0,96	3,54
273	10 000	10 000	200	50	MIX	BM	1	10	71	0,01	270	0,74	0,80	0,05	-0,83	2,30	0,00	0,15	0,51	1,00	4,44
274	5 000	15 000	500	10	2PX	BM	3	3	1210	0,01	270	0,74	0,86	0,05	-0,94	2,42	0,00	0,20	0,44	0,98	6,76
275	5 000	15 000	25	200	2PX	BM	3	3	1210	0,01	270	0,74	0,85	0,05	-0,93	2,41	0,00	0,20	0,46	0,92	5,28
276	5 000	15 000	25	200	MIX	BM	1	5	1480	0,01	270	0,74	0,93	0,06	-1,08	2,56	0,00	0,16	0,42	0,92	5,77
277	15 000	5 000	200	75	MIX	BM	2	5	248	0,05	270	0,74	0,63	0,04	-0,50	1,98	0,00	0,30	0,59	1,03	3,77
278	15 000	5 000	500	30	2PX	BM	2	5	248	0,05	270	0,74	0,57	0,03	-0,37	1,86	0,00	0,31	0,62	1,08	2,76
279	10 000	10 000	500	20	2PX	BM	1	5	988	0,05	270	0,75	0,81	0,05	-0,83	2,32	0,00	0,18	0,44	1,02	4,06
280	10 000	10 000	500	20	2PX	BM	1	10	71	0,01	270	0,75	0,65	0,04	-0,53	2,03	0,00	0,27	0,60	1,04	3,48
281	10 000	10 000	500	20	MIX	BM	1	3	2419	0,05	270	0,75	0,67	0,04	-0,56	2,07	0,00	0,29	0,59	0,96	4,11
282	10 000	10 000	25	400	MIX	BM	1	5	988	0,05	270	0,75	0,79	0,05	-0,80	2,30	0,00	0,17	0,54	1,09	5,36
283	10 000	10 000	500	20	MIX	BM	1	5	988	0,05	270	0,75	0,81	0,05	-0,84	2,35	0,00	0,20	0,50	0,99	4,72
284	15 000	5 000	250	60	2PX	BM	1	10	37	0,05	270	0,75	0,65	0,04	-0,51	2,02	0,00	0,33	0,59	1,05	4,06
285	15 000	5 000	50	300	2PX	BM	2	5	248	0,05	270	0,76	0,66	0,04	-0,54	2,06	0,00	0,28	0,59	0,99	3,71
286	5 000	15 000	250	20	2PX	BM	3	5	494	0,01	270	0,76	0,75	0,05	-0,70	2,22	0,00	0,21	0,57	1,04	4,07

Tab. C.4: Statystyki opisowe wyników algorytmu HIA dla $\hat{\Omega} = 30$ (c.d.)

#	G _A	S _A	$\hat{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	n	$\bar{x}[\%]$	s[%]	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
287	15 000	5 000	100	150	2PX	BM	1	10	37	0,05	270	0,76	0,74	0,04	-0,68	2,21	0,00	0,24	0,54	1,07	5,30
288	10 000	10 000	250	40	MIX	BM	1	10	71	0,01	270	0,76	0,76	0,05	-0,73	2,25	0,00	0,22	0,53	1,07	4,00
289	15 000	5 000	25	600	2PX	BM	2	5	248	0,01	270	0,77	0,85	0,05	-0,91	2,44	0,00	0,19	0,49	1,03	4,82
290	10 000	10 000	100	100	MIX	BM	1	10	71	0,01	270	0,77	0,82	0,05	-0,84	2,38	0,00	0,20	0,53	1,01	5,31
291	10 000	10 000	200	50	MIX	BM	2	3	1210	0,05	270	0,77	0,55	0,03	-0,30	1,84	0,01	0,40	0,63	1,00	2,97
292	5 000	15 000	500	10	2PX	BM	5	3	727	0,01	270	0,77	0,78	0,05	-0,75	2,30	0,00	0,28	0,56	0,99	5,77
293	15 000	5 000	50	300	2PX	BM	1	10	37	0,01	270	0,78	0,76	0,05	-0,72	2,27	0,00	0,22	0,52	1,10	3,73
294	10 000	10 000	250	40	MIX	BM	1	5	988	0,05	270	0,78	0,82	0,05	-0,83	2,38	0,00	0,19	0,51	1,03	4,56
295	10 000	10 000	50	200	2PX	BM	1	10	71	0,01	270	0,78	0,79	0,05	-0,77	2,33	0,00	0,24	0,53	1,00	4,20
296	15 000	5 000	500	30	2PX	BM	1	10	37	0,05	270	0,78	0,67	0,04	-0,53	2,09	0,00	0,28	0,62	1,09	4,06
297	15 000	5 000	100	150	2PX	BM	1	3	1210	0,05	270	0,79	0,58	0,04	-0,35	1,92	0,01	0,41	0,67	1,03	3,88
298	5 000	15 000	500	10	2PX	BM	4	3	908	0,01	270	0,79	0,87	0,05	-0,91	2,49	0,00	0,22	0,52	1,07	5,80
299	5 000	15 000	25	200	2PX	BM	4	3	908	0,01	270	0,79	0,80	0,05	-0,77	2,36	0,00	0,26	0,53	1,05	3,98
300	15 000	5 000	250	60	2PX	BM	1	3	1210	0,05	270	0,80	0,55	0,03	-0,27	1,87	0,03	0,45	0,68	1,01	3,73
301	15 000	5 000	100	150	2PX	BM	1	5	494	0,05	270	0,80	0,74	0,05	-0,66	2,26	0,00	0,29	0,61	1,12	5,50
302	15 000	5 000	500	30	MIX	BM	1	10	37	0,01	270	0,80	0,70	0,04	-0,58	2,18	0,00	0,28	0,63	1,10	3,94
303	10 000	10 000	25	400	2PX	BM	1	5	988	0,05	270	0,80	0,88	0,05	-0,92	2,53	0,00	0,22	0,52	0,98	5,05
304	15 000	5 000	100	150	MIX	BM	2	5	248	0,05	270	0,80	0,65	0,04	-0,47	2,08	0,00	0,33	0,60	1,12	3,75
305	10 000	10 000	250	40	2PX	BM	1	10	71	0,05	270	0,80	0,66	0,04	-0,49	2,10	0,00	0,30	0,65	1,15	3,35
306	5 000	15 000	200	25	MIX	BM	1	10	106	0,01	270	0,81	0,79	0,05	-0,75	2,36	0,00	0,22	0,64	1,11	4,46
307	15 000	5 000	50	300	2PX	BM	1	5	494	0,05	270	0,81	0,71	0,04	-0,57	2,19	0,00	0,30	0,60	1,14	3,63
308	10 000	10 000	200	50	2PX	BM	1	10	71	0,05	270	0,81	0,75	0,05	-0,66	2,29	0,00	0,28	0,62	1,13	4,14
309	15 000	5 000	200	75	2PX	BM	2	3	605	0,05	270	0,81	0,52	0,03	-0,20	1,83	0,08	0,46	0,71	1,06	3,32
310	15 000	5 000	200	75	MIX	BM	1	5	494	0,05	270	0,82	0,70	0,04	-0,56	2,20	0,00	0,31	0,65	1,08	4,51
311	10 000	10 000	100	100	2PX	BM	1	10	71	0,05	270	0,82	0,78	0,05	-0,71	2,35	0,00	0,28	0,62	1,07	4,22
312	15 000	5 000	250	60	MIX	BM	1	10	37	0,05	270	0,82	0,70	0,04	-0,55	2,19	0,00	0,30	0,67	1,12	4,05
313	5 000	15 000	25	200	2PX	BM	5	5	297	0,01	270	0,82	0,85	0,05	-0,85	2,50	0,00	0,24	0,56	1,09	5,61
314	5 000	15 000	250	20	2PX	BM	1	10	106	0,01	270	0,83	0,78	0,05	-0,70	2,35	0,00	0,26	0,66	1,19	5,39
315	15 000	5 000	50	300	2PX	BM	1	10	37	0,05	270	0,83	0,75	0,05	-0,64	2,29	0,00	0,27	0,61	1,18	3,79
316	15 000	5 000	100	150	MIX	BM	1	5	494	0,05	270	0,83	0,75	0,05	-0,65	2,30	0,00	0,29	0,63	1,15	5,52
317	10 000	10 000	50	200	MIX	BM	1	10	71	0,01	270	0,83	0,83	0,05	-0,79	2,45	0,00	0,22	0,63	1,15	4,24
318	15 000	5 000	200	75	MIX	BM	1	10	37	0,05	270	0,84	0,74	0,05	-0,62	2,29	0,00	0,32	0,69	1,12	4,43

Tab. C.4: Statystyki opisowe wyników algorytmu $\mathbb{H}_A$ dla $\tilde{\Omega} = 30$ (c.d.)

#	$\tilde{G}_A$	$\tilde{S}_A$	$\tilde{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	n	$\bar{x}[\%]$	s[%]	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
319	15 000	5 000	100	150	2PX	BM	2	3	605	0,05	270	0,84	0,58	0,04	-0,30	1,99	0,01	0,41	0,69	1,14	3,07
320	5 000	15 000	25	200	2PX	BM	4	5	371	0,01	270	0,85	0,86	0,05	-0,83	2,53	0,00	0,26	0,59	1,10	5,71
321	15 000	5 000	100	150	MIX	BM	1	10	37	0,05	270	0,85	0,76	0,05	-0,65	2,34	0,00	0,32	0,63	1,09	4,56
322	15 000	5 000	50	300	2PX	BM	2	3	605	0,05	270	0,85	0,55	0,03	-0,22	1,92	0,00	0,46	0,77	1,16	2,99
323	15 000	5 000	500	30	MIX	BM	2	5	248	0,05	270	0,85	0,74	0,05	-0,61	2,31	0,00	0,32	0,69	1,15	3,57
324	10 000	10 000	100	100	MIX	BM	1	10	71	0,05	270	0,86	0,76	0,05	-0,64	2,35	0,00	0,31	0,72	1,15	4,84
325	15 000	5 000	25	600	MIX	BM	2	5	248	0,01	270	0,86	0,87	0,05	-0,84	2,56	0,00	0,21	0,59	1,18	4,76
326	15 000	5 000	50	300	MIX	BM	2	5	248	0,05	270	0,86	0,81	0,05	-0,73	2,45	0,00	0,33	0,62	1,10	5,06
327	15 000	5 000	50	300	2PX	BM	1	3	1210	0,05	270	0,86	0,66	0,04	-0,43	2,15	0,02	0,43	0,68	1,04	3,70
328	5 000	15 000	50	100	2PX	BM	1	10	106	0,01	270	0,86	0,95	0,06	-1,00	2,73	0,00	0,25	0,58	1,15	6,42
329	5 000	15 000	100	50	MIX	BM	1	10	106	0,01	270	0,86	0,84	0,05	-0,79	2,51	0,00	0,25	0,63	1,19	4,42
330	15 000	5 000	500	30	2PX	BM	1	5	494	0,05	270	0,87	0,75	0,05	-0,60	2,34	0,00	0,31	0,68	1,29	4,18
331	15 000	5 000	25	600	2PX	BM	1	5	494	0,01	270	0,87	0,88	0,05	-0,86	2,60	0,00	0,24	0,63	1,09	5,14
332	15 000	5 000	100	150	MIX	BM	1	3	1210	0,05	270	0,87	0,65	0,04	-0,40	2,14	0,00	0,45	0,70	1,13	4,18
333	15 000	5 000	50	300	MIX	BM	1	5	494	0,05	270	0,88	0,82	0,05	-0,74	2,49	0,00	0,28	0,66	1,18	4,10
334	15 000	5 000	200	75	MIX	BM	1	3	1210	0,05	270	0,88	0,62	0,04	-0,33	2,08	0,07	0,45	0,70	1,16	3,86
335	15 000	5 000	250	60	MIX	BM	1	5	494	0,05	270	0,88	0,81	0,05	-0,71	2,47	0,00	0,30	0,68	1,29	4,53
336	15 000	5 000	50	300	MIX	BM	1	10	37	0,01	270	0,88	0,88	0,05	-0,84	2,60	0,00	0,25	0,62	1,23	6,26
337	15 000	5 000	250	60	2PX	BM	2	3	605	0,05	270	0,88	0,56	0,03	-0,21	1,98	0,02	0,55	0,77	1,13	3,84
338	15 000	5 000	25	600	MIX	BM	2	5	248	0,05	270	0,89	0,81	0,05	-0,69	2,46	0,00	0,28	0,66	1,23	3,78
339	10 000	10 000	500	20	MIX	BM	1	10	71	0,01	270	0,89	0,86	0,05	-0,80	2,58	0,00	0,29	0,67	1,25	4,58
340	5 000	15 000	25	200	2PX	BM	3	5	494	0,01	270	0,89	0,87	0,05	-0,82	2,60	0,00	0,28	0,65	1,16	5,54
341	15 000	5 000	25	600	MIX	BM	1	5	494	0,01	270	0,89	0,82	0,05	-0,72	2,50	0,00	0,28	0,72	1,22	3,93
342	10 000	10 000	200	50	MIX	BM	1	10	71	0,05	270	0,90	0,77	0,05	-0,61	2,40	0,00	0,34	0,75	1,28	4,05
343	15 000	5 000	25	600	2PX	BM	2	5	248	0,05	270	0,90	0,84	0,05	-0,74	2,53	0,00	0,32	0,66	1,19	4,96
344	15 000	5 000	25	600	MIX	BM	1	3	1210	0,05	270	0,90	0,64	0,04	-0,35	2,15	0,04	0,47	0,75	1,21	4,24
345	15 000	5 000	250	60	MIX	BM	2	3	605	0,05	270	0,90	0,59	0,04	-0,25	2,05	0,02	0,49	0,77	1,12	3,49
346	15 000	5 000	50	300	MIX	BM	1	3	1210	0,05	270	0,90	0,62	0,04	-0,31	2,12	0,00	0,44	0,77	1,23	4,49
347	5 000	15 000	500	10	2PX	BM	5	5	297	0,01	270	0,90	0,89	0,05	-0,85	2,65	0,00	0,31	0,66	1,25	6,16
348	5 000	15 000	50	100	MIX	BM	1	10	106	0,01	270	0,91	0,96	0,06	-0,96	2,79	0,00	0,21	0,64	1,29	5,34
349	15 000	5 000	250	60	MIX	BM	1	3	1210	0,05	270	0,91	0,67	0,04	-0,40	2,22	0,00	0,48	0,76	1,13	4,18
350	15 000	5 000	500	30	MIX	BM	1	10	37	0,05	270	0,92	0,78	0,05	-0,61	2,45	0,00	0,34	0,76	1,25	4,58

Tab. C.4: Statystyki opisowe wyników algorytmu HIA dla $\hat{\Omega} = 30$ (c.d.)

#	G _A	S _A	$\hat{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	n	$\bar{x}[\%]$	s[%]	$s_E[\%]$	-95[%]	+95[%]	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
351	5 000	15 000	500	10	2PX	BM	4	5	371	0,01	270	0,92	0,88	0,05	-0,80	2,63	0,00	0,32	0,62	1,28	5,50
352	10 000	10 000	500	20	2PX	BM	1	10	71	0,05	270	0,92	0,78	0,05	-0,62	2,46	0,00	0,33	0,72	1,26	4,15
353	5 000	15 000	100	50	2PX	BM	1	10	106	0,05	270	0,92	0,77	0,05	-0,59	2,43	0,00	0,38	0,74	1,26	4,45
354	15 000	5 000	100	150	MIX	BM	2	3	605	0,05	270	0,92	0,62	0,04	-0,29	2,13	0,05	0,52	0,78	1,17	3,99
355	5 000	15 000	250	20	MIX	BM	1	10	106	0,01	270	0,92	0,94	0,06	-0,91	2,76	0,00	0,27	0,68	1,23	4,94
356	5 000	15 000	200	25	2PX	BM	1	10	106	0,05	270	0,93	0,80	0,05	-0,65	2,50	0,00	0,34	0,75	1,25	4,93
357	15 000	5 000	25	600	2PX	BM	1	3	1210	0,05	270	0,93	0,74	0,05	-0,53	2,39	0,00	0,41	0,72	1,25	4,72
358	15 000	5 000	200	75	MIX	BM	2	3	605	0,05	270	0,94	0,62	0,04	-0,27	2,16	0,09	0,51	0,82	1,22	4,18
359	15 000	5 000	500	30	MIX	BM	1	5	494	0,05	270	0,94	0,83	0,05	-0,67	2,56	0,00	0,35	0,73	1,25	4,36
360	15 000	5 000	50	300	MIX	BM	1	10	37	0,05	270	0,94	0,89	0,05	-0,81	2,70	0,00	0,29	0,70	1,33	6,09
361	15 000	5 000	500	30	2PX	BM	1	3	1210	0,05	270	0,95	0,61	0,04	-0,26	2,15	0,05	0,52	0,82	1,25	3,91
362	15 000	5 000	50	300	MIX	BM	2	3	605	0,05	270	0,95	0,58	0,04	-0,19	2,09	0,08	0,53	0,85	1,26	3,38
363	10 000	10 000	50	200	MIX	BM	1	10	71	0,05	270	0,95	0,92	0,06	-0,86	2,76	0,00	0,37	0,78	1,26	6,31
364	10 000	10 000	50	200	2PX	BM	1	10	71	0,05	270	0,95	0,86	0,05	-0,72	2,63	0,00	0,31	0,72	1,37	5,95
365	5 000	15 000	500	10	2PX	BM	3	5	494	0,01	270	0,96	0,92	0,06	-0,84	2,76	0,00	0,36	0,65	1,28	6,63
366	15 000	5 000	500	30	2PX	BM	2	3	605	0,05	270	0,96	0,56	0,03	-0,14	2,06	0,15	0,58	0,85	1,19	3,25
367	10 000	10 000	25	400	2PX	BM	1	10	71	0,01	270	0,96	1,07	0,07	-1,13	3,06	0,00	0,26	0,63	1,31	7,70
368	5 000	15 000	500	10	2PX	BM	1	10	106	0,01	270	0,97	0,87	0,05	-0,73	2,67	0,00	0,32	0,74	1,44	4,32
369	5 000	15 000	50	100	2PX	BM	1	10	106	0,05	270	0,97	0,96	0,06	-0,91	2,86	0,00	0,30	0,70	1,29	6,28
370	10 000	10 000	250	40	MIX	BM	1	10	71	0,05	270	0,98	0,86	0,05	-0,72	2,67	0,00	0,32	0,80	1,39	5,72
371	10 000	10 000	25	400	MIX	BM	1	10	71	0,01	270	0,99	0,93	0,06	-0,83	2,81	0,00	0,32	0,76	1,40	5,99
372	15 000	5 000	25	600	2PX	BM	2	3	605	0,05	270	0,99	0,69	0,04	-0,35	2,34	0,00	0,51	0,85	1,31	3,77
373	5 000	15 000	100	50	MIX	BM	1	10	106	0,05	270	0,99	0,88	0,05	-0,73	2,71	0,00	0,33	0,78	1,46	4,42
374	5 000	15 000	50	100	MIX	BM	1	10	106	0,05	270	0,99	0,88	0,05	-0,74	2,73	0,00	0,34	0,79	1,33	5,35
375	15 000	5 000	500	30	MIX	BM	1	3	1210	0,05	270	1,00	0,72	0,04	-0,41	2,40	0,00	0,50	0,82	1,31	3,84
376	15 000	5 000	25	600	MIX	BM	2	3	605	0,05	270	1,00	0,69	0,04	-0,34	2,35	0,06	0,48	0,84	1,32	3,33
377	15 000	5 000	25	600	MIX	BM	1	5	494	0,05	270	1,00	0,99	0,06	-0,93	2,94	0,00	0,33	0,75	1,41	7,69
378	15 000	5 000	25	600	2PX	BM	1	5	494	0,05	270	1,01	0,88	0,05	-0,71	2,73	0,00	0,38	0,72	1,51	4,88
379	15 000	5 000	25	600	2PX	BM	1	10	37	0,01	270	1,02	0,99	0,06	-0,93	2,97	0,00	0,35	0,76	1,38	6,36
380	5 000	15 000	25	200	MIX	BM	1	10	106	0,01	270	1,03	1,06	0,06	-1,05	3,10	0,00	0,27	0,74	1,46	6,58
381	5 000	15 000	200	25	MIX	BM	1	10	106	0,05	270	1,04	0,91	0,06	-0,74	2,82	0,00	0,36	0,80	1,39	4,62
382	5 000	15 000	25	200	2PX	BM	1	10	106	0,01	270	1,04	1,01	0,06	-0,94	3,03	0,00	0,30	0,71	1,50	5,25

Tab. C.4: Statystyki opisowe wyników algorytmu $\mathbb{H}\mathbb{A}$ dla $\tilde{\Omega} = 30$ (c.d.)

#	$\tilde{G}\mathbb{A}$	$\tilde{S}\mathbb{A}$	$\tilde{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	$-95[\%]$	$+95[\%]$	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
383	5 000	15 000	250	20	2PX	BM	1	10	106	0,05	270	1,06	0,89	0,05	-0,69	2,80	0,00	0,37	0,84	1,37	4,19
384	15 000	5 000	25	600	2PX	BM	1	10	37	0,05	270	1,06	1,00	0,06	-0,89	3,02	0,00	0,32	0,78	1,47	5,41
385	10 000	10 000	500	20	MIX	BM	1	10	71	0,05	270	1,06	0,89	0,05	-0,68	2,81	0,00	0,39	0,82	1,46	4,53
386	5 000	15 000	500	10	MIX	BM	1	10	106	0,01	270	1,07	0,95	0,06	-0,78	2,92	0,00	0,38	0,86	1,47	5,08
387	15 000	5 000	25	600	MIX	BM	1	10	37	0,01	270	1,07	0,90	0,05	-0,69	2,82	0,00	0,37	0,84	1,52	4,21
388	5 000	15 000	500	10	2PX	BM	1	10	106	0,05	270	1,07	0,97	0,06	-0,83	2,98	0,00	0,39	0,75	1,49	5,68
389	15 000	5 000	500	30	MIX	BM	2	3	605	0,05	270	1,08	0,70	0,04	-0,30	2,45	0,13	0,59	0,90	1,28	3,85
390	5 000	15 000	250	20	MIX	BM	1	10	106	0,05	270	1,09	0,98	0,06	-0,82	3,00	0,00	0,31	0,85	1,52	5,50
391	10 000	10 000	25	400	MIX	BM	1	10	71	0,05	270	1,10	0,98	0,06	-0,82	3,03	0,00	0,34	0,81	1,57	4,70
392	10 000	10 000	25	400	2PX	BM	1	10	71	0,05	270	1,12	0,94	0,06	-0,72	2,96	0,00	0,41	0,90	1,56	4,92
393	5 000	15 000	25	200	MIX	BM	1	10	106	0,05	270	1,13	1,08	0,07	-1,00	3,26	0,00	0,41	0,79	1,43	6,00
394	5 000	15 000	25	200	2PX	BM	1	10	106	0,05	270	1,14	1,04	0,06	-0,91	3,18	0,00	0,32	0,83	1,63	5,52
395	5 000	15 000	500	10	MIX	BM	1	10	106	0,05	270	1,14	1,11	0,07	-1,02	3,31	0,00	0,35	0,85	1,59	7,27
396	15 000	5 000	25	600	MIX	BM	1	10	37	0,05	270	1,16	0,93	0,06	-0,66	2,97	0,00	0,45	0,95	1,62	3,81

Tab. C.5: Statystyki opisowe wyników wybranych metaheurystyk dla modeli z liczbą czynności $\tilde{\Omega} \in \{10; 30; 60; 90\}$

$\tilde{\Omega}$	MH	n	$\bar{x}[\%]$	$s[\%]$	$s_E[\%]$	$-95[\%]$	$+95[\%]$	Min[%]	Q25[%]	Q50[%]	Q75[%]	Max[%]
10	SA	90	0,00	0,03	0,00	-0,05	0,06	0,00	0,00	0,00	0,00	0,26
10	GA	90	0,01	0,06	0,01	-0,10	0,12	0,00	0,00	0,00	0,00	0,44
10	HA	90	0,00	0,01	0,00	-0,02	0,02	0,00	0,00	0,00	0,00	0,10
10	TS	90	0,02	0,07	0,01	-0,12	0,16	0,00	0,00	0,00	0,00	0,49
30	SA	270	0,41	0,45	0,03	-0,46	1,29	0,00	0,09	0,29	0,58	3,02
30	GA	270	0,77	0,70	0,04	-0,60	2,15	0,00	0,29	0,58	1,06	3,96
30	HA	270	0,34	0,48	0,03	-0,60	1,27	0,00	0,03	0,16	0,44	2,70
30	TS	270	5,23	2,36	0,14	0,61	9,84	0,49	3,48	4,88	6,72	15,24
60	SA	270	1,29	1,22	0,07	-1,10	3,68	0,00	0,38	1,01	1,71	7,41
60	GA	270	3,17	1,35	0,08	0,53	5,81	0,00	2,26	3,05	3,93	9,04
60	HA	270	0,06	0,31	0,02	-0,55	0,67	0,00	0,00	0,00	0,00	4,26
60	TS	270	13,29	3,62	0,22	6,19	20,38	5,58	10,41	13,11	15,41	24,73
90	SA	270	3,26	1,83	0,11	-0,33	6,84	0,00	1,93	3,03	4,26	9,41
90	GA	270	6,37	2,05	0,12	2,35	10,39	0,37	4,95	6,35	7,48	15,84
90	HA	270	0,01	0,05	0,00	-0,09	0,11	0,00	0,00	0,00	0,00	0,57
90	TS	270	24,34	5,15	0,31	14,24	34,43	9,28	20,77	23,93	27,48	39,90

Tabele wyników analizy wariancji i testów *post-hoc*

Niniejszy załącznik zawiera szczegółowe wyniki analizy wariancji i testów *post-hoc* dla eksperymentów opisywanych w p. 6. Statystyki opisowe analizowanych eksperymentów znajdują się w zał. C. W zestawieniach zastosowano następujące oznaczenia:

Symbol	Znaczenie
df1	liczba stopni swobody w liczniku ($df1 = k - 1$, gdzie k oznacza liczbę zabiegów) wspólna dla wszystkich opisywanych testów w jednoczynnikowej analizie wariancji
df2	liczba stopni swobody w mianowniku różna dla poszczególnych testów
L	wartość sprawdzianu statystyki L dla testu jednorodności wariancji Levene'a
F	wartość sprawdzianu statystyki F dla testu równości średnich ANOVA
F_W	wartość sprawdzianu statystyki F dla testu równości średnich Welch'a
F_{BF}	wartość sprawdzianu statystyki F dla testu równości średnich Browna-Forsythe'a
$p(H_0)$	krytyczny poziom istotności, wielkość unormowana wskazująca na wiarygodność hipotezy zerowej testu

W przypadku testu Levene'a hipoteza zerowa zakłada, że wariancje we wszystkich grupach są jednorodne ($H_0 : \sigma_0 = \sigma_1 = \dots = \sigma_k$). Dla pozostałych testów (ANOVA, Welch'a, Browna-Forsythe'a) hipoteza zerowa zakłada, że średnie we wszystkich grupach są równe ($H_0 : \bar{x}_0 = \bar{x}_1 = \dots = \bar{x}_k$). Wszystkie stosowane testy są testami prawostronnymi. W analizie wyników przyjęto poziom istotności $\alpha = 0,05$. Dla zachowania spójności i poprawy czytelności przedstawiono wyniki testów *post-hoc* również w wypadku potwierdzenia hipotezy o równości średnich.

Dla wskazania grup statystycznie jednorodnych w ramach wybranych testów *post-hoc* zastosowano następujące oznaczenia:

Symbol	Znaczenie
[	otwiera grupę zabiegów, których różnica średnich $\bar{\epsilon}$ jest statystycznie nieistotna
	rozdziela zabiegi, których różnica średnich $\bar{\epsilon}$ jest statystycznie nieistotna
]	zamyka grupę zabiegów, których różnica średnich $\bar{\epsilon}$ jest statystycznie nieistotna

Przykładowo: [A | B [C] D | E] [F] oznacza, że wyodrębniono trzy grupy zabiegów w ramach których różnice średnich są statystycznie nieistotne: (1) A, B i C, (2) C, D i E oraz (3) F.

Symbolem ★ oznaczono parametry metaheurystyki będące przedmiotem porównania.

Tab. D.1: Podsumowanie wyników jednoczynnikowej analizy wariancji dla $\hat{\mathcal{P}}$ i $g_{\max}$ w GA. Wielkość próby w każdej komórce wynosi $n = 270$.

#	$\mathcal{P}$	$g_{\max}$	Parametry GA				Test Levene'a			Test ANOVA			Test Welch'a			Test Brown-Forsythe'a					
			E	α	p_{α}	β	p_{β}	ζ	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_w	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	★	★	–	1PX	0,90	HM	0,10	2	3	1076	10,89	<0,001	1076	58,99	<0,001	593	47,99	<0,001	991	58,99	<0,001
2	★	★	–	PSX	0,90	HM	0,10	2	3	1076	3,12	0,025	1076	10,28	<0,001	597	10,68	<0,001	1061	10,28	<0,001
3	★	★	–	2PX	0,90	HM	0,10	2	3	1076	20,51	<0,001	1076	52,07	<0,001	589	37,72	<0,001	881	52,07	<0,001
4	★	★	–	UX	0,90	HM	0,10	2	3	1076	5,64	<0,001	1076	17,68	<0,001	595	15,91	<0,001	1028	17,68	<0,001
5	★	★	–	MIX	0,90	HM	0,10	2	3	1076	2,75	0,042	1076	19,35	<0,001	597	17,01	<0,001	1053	19,35	<0,001
6	★	★	–	1PX	0,90	BM	0,10	2	3	1076	16,98	<0,001	1076	82,64	<0,001	591	64,49	<0,001	909	82,64	<0,001
7	★	★	–	PSX	0,90	BM	0,10	2	3	1076	4,45	0,004	1076	38,13	<0,001	596	36,29	<0,001	1050	38,13	<0,001
8	★	★	–	2PX	0,90	BM	0,10	2	3	1076	20,92	<0,001	1076	106,09	<0,001	591	78,74	<0,001	907	106,09	<0,001
9	★	★	–	UX	0,90	BM	0,10	2	3	1076	13,66	<0,001	1076	80,76	<0,001	593	64,11	<0,001	963	80,76	<0,001
10	★	★	–	MIX	0,90	BM	0,10	2	3	1076	11,43	<0,001	1076	67,64	<0,001	594	55,44	<0,001	990	67,64	<0,001
11	★	★	–	1PX	0,90	MM	0,10	2	3	1076	12,42	<0,001	1076	69,91	<0,001	594	55,24	<0,001	988	69,91	<0,001
12	★	★	–	PSX	0,90	MM	0,10	2	3	1076	1,91	0,126	1076	13,11	<0,001	597	11,80	<0,001	1059	13,11	<0,001
13	★	★	–	2PX	0,90	MM	0,10	2	3	1076	24,52	<0,001	1076	99,96	<0,001	589	72,35	<0,001	880	99,96	<0,001
14	★	★	–	UX	0,90	MM	0,10	2	3	1076	5,98	<0,001	1076	56,75	<0,001	595	50,88	<0,001	1034	56,75	<0,001
15	★	★	–	MIX	0,90	MM	0,10	2	3	1076	9,34	<0,001	1076	55,61	<0,001	595	45,99	<0,001	1021	55,61	<0,001
16	★	★	+	1PX	0,90	HM	0,10	2	3	1076	23,48	<0,001	1076	48,56	<0,001	589	42,67	<0,001	946	48,56	<0,001
17	★	★	+	PSX	0,90	HM	0,10	2	3	1076	8,06	<0,001	1076	24,32	<0,001	596	21,37	<0,001	1024	24,32	<0,001
18	★	★	+	2PX	0,90	HM	0,10	2	3	1076	29,76	<0,001	1076	43,56	<0,001	588	33,13	<0,001	891	43,56	<0,001
19	★	★	+	UX	0,90	HM	0,10	2	3	1076	0,81	0,490	1076	3,46	0,016	597	3,52	0,015	1069	3,46	0,016
20	★	★	+	MIX	0,90	HM	0,10	2	3	1076	12,94	<0,001	1076	21,71	<0,001	593	15,86	<0,001	970	21,71	<0,001
21	★	★	+	1PX	0,90	BM	0,10	2	3	1076	39,17	<0,001	1076	33,15	<0,001	588	25,35	<0,001	813	33,15	<0,001
22	★	★	+	PSX	0,90	BM	0,10	2	3	1076	3,49	0,015	1076	19,47	<0,001	596	19,94	<0,001	1051	19,47	<0,001
23	★	★	+	2PX	0,90	BM	0,10	2	3	1076	44,95	<0,001	1076	57,04	<0,001	587	44,15	<0,001	825	57,04	<0,001
24	★	★	+	UX	0,90	BM	0,10	2	3	1076	3,78	0,010	1076	3,50	0,015	596	3,15	0,025	1041	3,50	0,015
25	★	★	+	MIX	0,90	BM	0,10	2	3	1076	7,41	<0,001	1076	12,74	<0,001	594	13,46	<0,001	994	12,74	<0,001
26	★	★	+	1PX	0,90	MM	0,10	2	3	1076	30,73	<0,001	1076	48,73	<0,001	590	35,48	<0,001	883	48,73	<0,001
27	★	★	+	PSX	0,90	MM	0,10	2	3	1076	4,34	0,005	1076	14,31	<0,001	595	14,78	<0,001	1034	14,31	<0,001
28	★	★	+	2PX	0,90	MM	0,10	2	3	1076	40,36	<0,001	1076	52,85	<0,001	587	41,20	<0,001	800	52,85	<0,001
29	★	★	+	UX	0,90	MM	0,10	2	3	1076	4,80	0,003	1076	6,18	<0,001	596	5,80	<0,001	1046	6,18	<0,001
30	★	★	+	MIX	0,90	MM	0,10	2	3	1076	6,08	<0,001	1076	16,82	<0,001	596	16,16	<0,001	1042	16,82	<0,001

Tab. D.2: Podsumowanie wyników testów *post-hoc* dla $\mathcal{P}$ i $g_{\max}$ w GA. W zestawieniu grup jednorodnych dla poprawy czytelności przedstawiono jedynie wartość $\mathcal{P}$. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów GA dla poniższych porównań przedstawiono w tab. D.1 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla ($\mathcal{P}$; $g_{\max}$)				Grupy jednorodne według $\mathcal{P}$			
	(50; 400)	(100; 200)	(200; 100)	(400; 50)	Tukey (HSD)	Tamhane (T2)	Games-Howell (GH)	
1	3,87	2,71	2,27	2,37	[200 400] [100 50]	[200 400] [100 50]	[200 400] [100 50]	
2	3,47	2,69	2,81	3,24	[100 200] [400 50]	[100 200] [400 50]	[100 200] [400 50]	
3	3,09	2,11	1,77	1,83	[200 400] [100 50]	[200 400] [100 50]	[200 400] [100 50]	
4	5,54	4,72	4,10	4,10	[200 400] [100 50]	[200 400] [100 50]	[200 400] [100 50]	
5	3,32	2,54	2,33	2,55	[200 100 400] [50]	[200 100 400] [50]	[200 100 400] [50]	
6	4,69	3,52	2,85	2,83	[400 200] [100 50]	[400 200] [100 50]	[400 200] [100 50]	
7	8,28	6,79	6,28	5,66	[400 200] [100 50]	[400 200] [100 50]	[400 200] [100 50]	
8	3,90	2,78	2,32	2,30	[400 200] [100 50]	[400 200] [100 50]	[400 200] [100 50]	
9	6,92	5,19	4,42	4,18	[400 200] [100 50]	[400 200] [100 50]	[400 200] [100 50]	
10	4,64	3,62	3,11	2,99	[400 200] [100 50]	[400 200] [100 50]	[400 200] [100 50]	
11	3,87	2,81	2,40	2,40	[400 200] [100 50]	[400 200] [100 50]	[400 200] [100 50]	
12	6,10	5,13	4,92	4,79	[400 200 100] [50]	[400 200 100] [50]	[400 200 100] [50]	
13	3,21	2,11	1,70	1,86	[200 400] [100 50]	[200 400] [100 50]	[200 400] [100 50]	
14	6,11	4,81	3,98	3,92	[400 200] [100 50]	[400 200] [100 50]	[400 200] [100 50]	
15	3,97	2,96	2,58	2,64	[200 400] [100 50]	[200 400] [100 50]	[200 400] [100 50]	
16	3,31	2,45	1,77	2,00	[200 400] [100 50]	[200 400] [100 50]	[200 400] [100 50]	
17	2,39	1,60	1,52	1,94	[200 100] [400 50]	[200 100] [400 50]	[200 100] [400 50]	
18	2,51	1,65	1,30	1,55	[200 400] [100 50]	[200 400 100] [50]	[200 400 100] [50]	
19	3,78	3,41	3,20	3,47	[200 100 400] [50]	[200 100 400] [50]	[200 100 400] [50]	
20	2,71	1,92	1,76	1,96	[200 100 400] [50]	[200 100 400] [50]	[200 100 400] [50]	
21	2,46	1,75	1,53	1,87	[200 100 400] [50]	[200 100 400] [50]	[200 100 400] [50]	
22	2,16	1,96	2,38	2,77	[100 50 200] [400]	[100 50 200] [400]	[100 50 200] [400]	
23	2,06	1,28	1,13	1,49	[200 100] [400] [50]	[200 100] [400] [50]	[200 100] [400] [50]	
24	3,48	3,13	3,01	3,23	[200 100 400] [50]	[200 100 400] [50]	[200 100 400] [50]	
25	1,97	1,61	1,63	2,03	[100 200] [50 400]	[100 200] [50 400]	[100 200] [50 400]	
26	2,53	1,61	1,42	1,74	[200 100 400] [50]	[200 100 400] [50]	[200 100 400] [50]	
27	2,21	1,74	1,93	2,46	[100 200] [50 400]	[100 200] [50 400]	[100 200] [50 400]	
28	1,86	1,17	0,93	1,27	[200 100 400] [50]	[200 100 400] [50]	[200 100 400] [50]	
29	3,51	2,94	2,99	3,24	[100 200 400] [50]	[100 200 400] [50]	[100 200 400] [50]	
30	2,01	1,45	1,51	1,85	[100 200] [400 50]	[100 200] [400 50]	[100 200] [400 50]	

Tab. D.3: Podsumowanie wyników jednoczynnikowej analizy wariancji dla α w $\mathbb{G}_A$. Wielkość próby w każdej komórce wynosi $n = 270$.

#	$\hat{\mathcal{D}}$	$g_{\max}$	E	α	p_α	Parametry $\mathbb{G}_A$			df1	Test Levene'a			Test ANOVA			Test Welch'a			Test Browna-Forsythe'a		
						β	p_β	ζ		df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_W	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	50	400	-	★	0,90	HM	0,10	2	4	1345	21,75	<0,001	1345	55,57	<0,001	669	35,26	<0,001	1073	55,57	<0,001
2	100	200	-	★	0,90	HM	0,10	2	4	1345	27,70	<0,001	1345	82,14	<0,001	667	49,78	<0,001	994	82,14	<0,001
3	200	100	-	★	0,90	HM	0,10	2	4	1345	26,36	<0,001	1345	68,06	<0,001	660	55,51	<0,001	1008	68,06	<0,001
4	400	50	-	★	0,90	HM	0,10	2	4	1345	34,98	<0,001	1345	70,76	<0,001	662	66,97	<0,001	1080	70,76	<0,001
5	50	400	-	★	0,90	BM	0,10	2	4	1345	46,48	<0,001	1345	157,16	<0,001	662	134,33	<0,001	1036	157,16	<0,001
6	100	200	-	★	0,90	BM	0,10	2	4	1345	74,59	<0,001	1345	177,93	<0,001	659	145,89	<0,001	872	177,93	<0,001
7	200	100	-	★	0,90	BM	0,10	2	4	1345	91,68	<0,001	1345	199,93	<0,001	657	151,51	<0,001	819	199,93	<0,001
8	400	50	-	★	0,90	BM	0,10	2	4	1345	79,00	<0,001	1345	161,64	<0,001	657	128,17	<0,001	875	161,64	<0,001
9	50	400	-	★	0,90	MM	0,10	2	4	1345	38,16	<0,001	1345	107,77	<0,001	664	98,21	<0,001	1034	107,77	<0,001
10	100	200	-	★	0,90	MM	0,10	2	4	1345	65,76	<0,001	1345	140,33	<0,001	660	130,44	<0,001	943	140,33	<0,001
11	200	100	-	★	0,90	MM	0,10	2	4	1345	72,63	<0,001	1345	149,08	<0,001	653	143,05	<0,001	847	149,08	<0,001
12	400	50	-	★	0,90	MM	0,10	2	4	1345	71,37	<0,001	1345	139,26	<0,001	655	127,57	<0,001	886	139,26	<0,001
13	50	400	+	★	0,90	HM	0,10	2	4	1345	6,20	<0,001	1345	26,31	<0,001	670	24,30	<0,001	1273	26,31	<0,001
14	100	200	+	★	0,90	HM	0,10	2	4	1345	21,89	<0,001	1345	58,65	<0,001	667	42,82	<0,001	1088	58,65	<0,001
15	200	100	+	★	0,90	HM	0,10	2	4	1345	24,23	<0,001	1345	73,94	<0,001	666	49,71	<0,001	1063	73,94	<0,001
16	400	50	+	★	0,90	HM	0,10	2	4	1345	31,99	<0,001	1345	70,13	<0,001	666	44,97	<0,001	1010	70,13	<0,001
17	50	400	+	★	0,90	BM	0,10	2	4	1345	21,03	<0,001	1345	46,61	<0,001	668	32,08	<0,001	1124	46,61	<0,001
18	100	200	+	★	0,90	BM	0,10	2	4	1345	33,58	<0,001	1345	100,68	<0,001	665	71,08	<0,001	1008	100,68	<0,001
19	200	100	+	★	0,90	BM	0,10	2	4	1345	52,27	<0,001	1345	118,00	<0,001	657	107,93	<0,001	933	118,00	<0,001
20	400	50	+	★	0,90	BM	0,10	2	4	1345	46,01	<0,001	1345	96,18	<0,001	661	90,99	<0,001	997	96,18	<0,001
21	50	400	+	★	0,90	MM	0,10	2	4	1345	15,37	<0,001	1345	50,37	<0,001	669	39,69	<0,001	1196	50,37	<0,001
22	100	200	+	★	0,90	MM	0,10	2	4	1345	20,88	<0,001	1345	93,85	<0,001	665	72,27	<0,001	1132	93,85	<0,001
23	200	100	+	★	0,90	MM	0,10	2	4	1345	40,70	<0,001	1345	122,29	<0,001	655	109,52	<0,001	959	122,29	<0,001
24	400	50	+	★	0,90	MM	0,10	2	4	1345	50,42	<0,001	1345	101,90	<0,001	658	96,11	<0,001	992	101,90	<0,001

Tab. D.4: Podsumowanie wyników testów *post-hoc* dla α w GA. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów GA dla poniższych porównań przedstawiono w tab. D.3 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla α				Grupy jednorodne według α			
	1PX	PSX	2PX	UX	MIX	Tukey (HSD)	Tamhane (T2)	Ganes-Howell (GH)
1	3,87	3,47	3,09	5,54	3,32	[2PX MIX PSX 1PX] [UX]	[2PX MIX PSX 1PX] [UX]	[2PX MIX PSX 1PX] [UX]
2	2,71	2,69	2,11	4,72	2,54	[2PX MIX PSX 1PX] [UX]	[2PX] [MIX PSX 1PX] [UX]	[2PX] [MIX PSX 1PX] [UX]
3	2,27	2,81	1,77	4,10	2,33	[2PX] [1PX MIX] [PSX] [UX]	[2PX] [1PX MIX] [PSX] [UX]	[2PX] [1PX MIX] [PSX] [UX]
4	2,37	3,24	1,83	4,10	2,55	[2PX] [1PX MIX] [PSX] [UX]	[2PX] [1PX MIX] [PSX] [UX]	[2PX] [1PX MIX] [PSX] [UX]
5	4,69	8,28	3,90	6,92	4,64	[2PX] [MIX 1PX] [UX] [PSX]	[2PX] [MIX 1PX] [UX] [PSX]	[2PX] [MIX 1PX] [UX] [PSX]
6	3,52	6,79	2,78	5,19	3,62	[2PX] [1PX MIX] [UX] [PSX]	[2PX] [1PX MIX] [UX] [PSX]	[2PX] [1PX MIX] [UX] [PSX]
7	2,85	6,28	2,32	4,42	3,11	[2PX] [1PX MIX] [UX] [PSX]	[2PX] [1PX MIX] [UX] [PSX]	[2PX] [1PX MIX] [UX] [PSX]
8	2,83	5,66	2,30	4,18	2,99	[2PX] [1PX MIX] [UX] [PSX]	[2PX] [1PX MIX] [UX] [PSX]	[2PX] [1PX MIX] [UX] [PSX]
9	3,87	6,10	3,21	6,11	3,97	[2PX] [1PX MIX] [PSX UX]	[2PX] [1PX MIX] [PSX UX]	[2PX] [1PX MIX] [PSX UX]
10	2,81	5,13	2,11	4,81	2,96	[2PX] [1PX MIX] [UX PSX]	[2PX] [1PX MIX] [UX PSX]	[2PX] [1PX MIX] [UX PSX]
11	2,40	4,92	1,70	3,98	2,58	[2PX] [1PX MIX] [UX] [PSX]	[2PX] [1PX MIX] [UX] [PSX]	[2PX] [1PX MIX] [UX] [PSX]
12	2,40	4,79	1,86	3,92	2,64	[2PX] [1PX MIX] [UX] [PSX]	[2PX] [1PX MIX] [UX] [PSX]	[2PX] [1PX MIX] [UX] [PSX]
13	3,31	2,39	2,51	3,78	2,71	[PSX 2PX MIX] [1PX] [UX]	[PSX 2PX MIX] [1PX UX]	[PSX 2PX MIX] [1PX UX]
14	2,45	1,60	1,65	3,41	1,92	[PSX 2PX MIX] [1PX] [UX]	[PSX 2PX MIX] [1PX] [UX]	[PSX 2PX MIX] [1PX] [UX]
15	1,77	1,52	1,30	3,20	1,76	[2PX PSX MIX 1PX] [UX]	[2PX PSX MIX 1PX] [UX]	[2PX PSX MIX 1PX] [UX]
16	2,00	1,94	1,55	3,47	1,96	[2PX] [PSX MIX 1PX] [UX]	[2PX] [PSX MIX 1PX] [UX]	[2PX] [PSX MIX 1PX] [UX]
17	2,46	2,16	2,06	3,48	1,97	[MIX 2PX PSX 1PX] [UX]	[MIX 2PX PSX 1PX] [UX]	[MIX 2PX PSX 1PX] [UX]
18	1,75	1,96	1,28	3,13	1,61	[2PX] [MIX 1PX PSX] [UX]	[2PX] [MIX 1PX PSX] [UX]	[2PX] [MIX 1PX PSX] [UX]
19	1,53	2,38	1,13	3,01	1,63	[2PX] [1PX MIX] [PSX] [UX]	[2PX] [1PX MIX] [PSX] [UX]	[2PX] [1PX MIX] [PSX] [UX]
20	1,87	2,77	1,49	3,23	2,03	[2PX] [1PX MIX] [PSX] [UX]	[2PX] [1PX MIX] [PSX] [UX]	[2PX] [1PX MIX] [PSX] [UX]
21	2,53	2,21	1,86	3,51	2,01	[2PX MIX PSX 1PX] [UX]	[2PX MIX PSX 1PX] [UX]	[2PX MIX PSX 1PX] [UX]
22	1,61	1,74	1,17	2,94	1,45	[2PX] [MIX 1PX PSX] [UX]	[2PX] [MIX 1PX PSX] [UX]	[2PX] [MIX 1PX PSX] [UX]
23	1,42	1,93	0,93	2,99	1,51	[2PX] [1PX MIX] [PSX] [UX]	[2PX] [1PX MIX] [PSX] [UX]	[2PX] [1PX MIX] [PSX] [UX]
24	1,74	2,46	1,27	3,24	1,85	[2PX] [1PX MIX] [PSX] [UX]	[2PX] [1PX MIX] [PSX] [UX]	[2PX] [1PX MIX] [PSX] [UX]

Tab. D.5: Podsumowanie wyników jednoczynnikowej analizy wariancji dla β w $\mathbb{GA}$ bez elityzmu. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry GA					Test Levene'a			Test ANOVA			Test Welch'a		Test Browna-Forsythe'a							
	$\mathcal{P}$	$g_{\max}$	E	α	p_{α}	β	p_{β}	ζ	df1	df2	L	$p(H_0)$	F	df2	F_W	$p(H_0)$	df2	F_{BF}	$p(H_0)$		
1	50	400	-	1PX	0,90	★	0,10	2	2	807	2,32	0,099	807	16,98	<0,001	534	15,45	<0,001	785	16,98	<0,001
2	100	200	-	1PX	0,90	★	0,10	2	2	807	3,24	0,040	807	24,02	<0,001	533	23,02	<0,001	785	24,02	<0,001
3	200	100	-	1PX	0,90	★	0,10	2	2	807	1,33	0,266	807	14,08	<0,001	536	13,65	<0,001	798	14,08	<0,001
4	400	50	-	1PX	0,90	★	0,10	2	2	807	0,84	0,430	807	11,43	<0,001	537	11,34	<0,001	803	11,43	<0,001
5	50	400	-	PSX	0,90	★	0,10	2	2	807	34,17	<0,001	807	202,54	<0,001	506	237,95	<0,001	701	202,54	<0,001
6	100	200	-	PSX	0,90	★	0,10	2	2	807	44,78	<0,001	807	183,47	<0,001	502	222,11	<0,001	685	183,47	<0,001
7	200	100	-	PSX	0,90	★	0,10	2	2	807	22,77	<0,001	807	126,14	<0,001	520	145,95	<0,001	739	126,14	<0,001
8	400	50	-	PSX	0,90	★	0,10	2	2	807	13,80	<0,001	807	72,08	<0,001	527	81,44	<0,001	763	72,08	<0,001
9	50	400	-	2PX	0,90	★	0,10	2	2	807	3,45	0,032	807	18,79	<0,001	534	19,29	<0,001	779	18,79	<0,001
10	100	200	-	2PX	0,90	★	0,10	2	2	807	3,61	0,027	807	27,09	<0,001	534	29,44	<0,001	775	27,09	<0,001
11	200	100	-	2PX	0,90	★	0,10	2	2	807	4,44	0,012	807	31,93	<0,001	535	32,54	<0,001	789	31,93	<0,001
12	400	50	-	2PX	0,90	★	0,10	2	2	807	4,67	0,010	807	19,36	<0,001	533	20,10	<0,001	775	19,36	<0,001
13	50	400	-	UX	0,90	★	0,10	2	2	807	2,67	0,070	807	16,40	<0,001	535	15,15	<0,001	789	16,40	<0,001
14	100	200	-	UX	0,90	★	0,10	2	2	807	2,75	0,065	807	2,85	0,059	534	3,05	0,048	776	2,85	0,059
15	200	100	-	UX	0,90	★	0,10	2	2	807	1,86	0,156	807	2,90	0,056	533	3,42	0,034	766	2,90	0,056
16	400	50	-	UX	0,90	★	0,10	2	2	807	3,22	0,040	807	1,08	0,341	536	1,18	0,308	791	1,08	0,341
17	50	400	-	MIX	0,90	★	0,10	2	2	807	0,43	0,650	807	37,10	<0,001	537	35,09	<0,001	802	37,10	<0,001
18	100	200	-	MIX	0,90	★	0,10	2	2	807	0,27	0,762	807	37,24	<0,001	537	36,23	<0,001	803	37,24	<0,001
19	200	100	-	MIX	0,90	★	0,10	2	2	807	1,41	0,245	807	21,74	<0,001	536	21,37	<0,001	792	21,74	<0,001
20	400	50	-	MIX	0,90	★	0,10	2	2	807	3,30	0,037	807	7,49	<0,001	532	7,77	<0,001	762	7,49	<0,001

Tab. D.6: Podsumowanie wyników testów *post-hoc* dla β w GA bez elityzmu. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów GA dla poniższych porównań przedstawiono w tab. D.5 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla β		Grupy jednorodne według β			
	HM	BM	MM	Tukey (HSD)	Tamhane (T2)	Games-Howell (GH)
1	3,87	4,69	3,87	[HM MM] [BM]	[HM MM] [BM]	[HM MM] [BM]
2	2,71	3,52	2,81	[HM MM] [BM]	[HM MM] [BM]	[HM MM] [BM]
3	2,27	2,85	2,40	[HM MM] [BM]	[HM MM] [BM]	[HM MM] [BM]
4	2,37	2,83	2,40	[HM MM] [BM]	[HM MM] [BM]	[HM MM] [BM]
5	3,47	8,28	6,10	[HM] [MM] [BM]	[HM] [MM] [BM]	[HM] [MM] [BM]
6	2,69	6,79	5,13	[HM] [MM] [BM]	[HM] [MM] [BM]	[HM] [MM] [BM]
7	2,81	6,28	4,92	[HM] [MM] [BM]	[HM] [MM] [BM]	[HM] [MM] [BM]
8	3,24	5,66	4,79	[HM] [MM] [BM]	[HM] [MM] [BM]	[HM] [MM] [BM]
9	3,09	3,90	3,21	[HM MM] [BM]	[HM MM] [BM]	[HM MM] [BM]
10	2,11	2,78	2,11	[MM HM] [BM]	[MM HM] [BM]	[MM HM] [BM]
11	1,77	2,32	1,70	[MM HM] [BM]	[MM HM] [BM]	[MM HM] [BM]
12	1,83	2,30	1,86	[HM MM] [BM]	[HM MM] [BM]	[HM MM] [BM]
13	5,54	6,92	6,11	[HM] [MM] [BM]	[HM MM] [BM]	[HM] [MM] [BM]
14	4,72	5,19	4,81	[HM MM BM]	[HM MM BM]	[HM MM BM]
15	4,10	4,42	3,98	[MM HM BM]	[MM HM BM]	[MM HM BM]
16	4,10	4,18	3,92	[MM HM BM]	[MM HM BM]	[MM HM BM]
17	3,32	4,64	3,97	[HM] [MM] [BM]	[HM] [MM] [BM]	[HM] [MM] [BM]
18	2,54	3,62	2,96	[HM] [MM] [BM]	[HM] [MM] [BM]	[HM] [MM] [BM]
19	2,33	3,11	2,58	[HM MM] [BM]	[HM MM] [BM]	[HM MM] [BM]
20	2,55	2,99	2,64	[HM MM] [BM]	[HM MM] [BM]	[HM MM] [BM]

Tab. D.7: Podsumowanie wyników jednoczynnikowej analizy wariancji dla β w GA z elityzmem. Wielkość próby w każdej komórce wynosi $n = 270$.

#	$\hat{\mathcal{P}}$	$g_{\max}$	E	Parametry GA				Test Levene'a		Test ANOVA		Test Welch'a		Test Browna-Forsythe'a							
				α	p_{α}	β	p_{β}	ζ	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_{BF}	$p(H_0)$			
1	50	400	+	1PX	0,90	★	0,10	2	2	807	10,26	<0,001	807	20,28	<0,001	532	17,26	<0,001	761	20,28	<0,001
2	100	200	+	1PX	0,90	★	0,10	2	2	807	28,53	<0,001	807	31,65	<0,001	521	24,04	<0,001	655	31,65	<0,001
3	200	100	+	1PX	0,90	★	0,10	2	2	807	14,05	<0,001	807	8,23	<0,001	526	6,83	0,001	714	8,23	<0,001
4	400	50	+	1PX	0,90	★	0,10	2	2	807	14,41	<0,001	807	3,74	0,024	525	3,40	0,034	694	3,74	0,024
5	50	400	+	PSX	0,90	★	0,10	2	2	807	6,22	0,002	807	1,92	0,147	532	1,91	0,149	780	1,92	0,147
6	100	200	+	PSX	0,90	★	0,10	2	2	807	0,61	0,545	807	5,82	0,003	537	5,93	0,003	800	5,82	0,003
7	200	100	+	PSX	0,90	★	0,10	2	2	807	2,10	0,124	807	30,79	<0,001	536	29,81	<0,001	791	30,79	<0,001
8	400	50	+	PSX	0,90	★	0,10	2	2	807	2,22	0,110	807	26,01	<0,001	536	28,19	<0,001	796	26,01	<0,001
9	50	400	+	2PX	0,90	★	0,10	2	2	807	17,23	<0,001	807	15,19	<0,001	528	12,82	<0,001	724	15,19	<0,001
10	100	200	+	2PX	0,90	★	0,10	2	2	807	16,48	<0,001	807	16,35	<0,001	519	12,57	<0,001	633	16,35	<0,001
11	200	100	+	2PX	0,90	★	0,10	2	2	807	21,32	<0,001	807	14,42	<0,001	520	14,10	<0,001	646	14,42	<0,001
12	400	50	+	2PX	0,90	★	0,10	2	2	807	10,73	<0,001	807	8,17	<0,001	528	9,02	<0,001	719	8,17	<0,001
13	50	400	+	UX	0,90	★	0,10	2	2	807	1,24	0,291	807	1,73	0,178	537	1,61	0,202	798	1,73	0,178
14	100	200	+	UX	0,90	★	0,10	2	2	807	11,16	<0,001	807	4,41	0,012	528	4,09	0,017	728	4,41	0,013
15	200	100	+	UX	0,90	★	0,10	2	2	807	4,23	0,015	807	1,07	0,344	534	0,94	0,391	779	1,07	0,344
16	400	50	+	UX	0,90	★	0,10	2	2	807	5,25	0,005	807	1,45	0,235	533	1,26	0,285	771	1,45	0,235
17	50	400	+	MIX	0,90	★	0,10	2	2	807	21,02	<0,001	807	21,69	<0,001	524	16,74	<0,001	685	21,69	<0,001
18	100	200	+	MIX	0,90	★	0,10	2	2	807	15,96	<0,001	807	13,48	<0,001	529	11,46	<0,001	736	13,48	<0,001
19	200	100	+	MIX	0,90	★	0,10	2	2	807	10,40	<0,001	807	3,20	0,042	519	2,75	0,065	671	3,20	0,042
20	400	50	+	MIX	0,90	★	0,10	2	2	807	2,26	0,106	807	1,74	0,176	533	2,06	0,129	767	1,74	0,176

Tab. D.8: Podsumowanie wyników testów *post-hoc* dla β w $\mathbb{GA}$ z elityzmem. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów $\mathbb{GA}$ dla poniższych porównań przedstawiono w tab. D.7 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla β		Grupy jednorodne według β					
			Tukey (HSD)		Tamhane (T2)		Games-Howell (GH)	
	HM	BM	BM	MM	BM	MM	BM	MM
1	3,31	2,46	2,53		[BM MM]	[HM]	[BM MM]	[HM]
2	2,45	1,75	1,61		[MM BM]	[HM]	[MM BM]	[HM]
3	1,77	1,53	1,42		[MM BM]	[HM]	[MM BM]	[HM]
4	2,00	1,87	1,74		[MM BM]	[HM]	[MM BM]	[HM]
5	2,39	2,16	2,21		[BM MM]	[HM]	[BM MM]	[HM]
6	1,60	1,96	1,74		[HM MM]	[BM]	[HM MM]	[BM]
7	1,52	2,38	1,93		[HM]	[MM]	[HM]	[MM]
8	1,94	2,77	2,46		[HM]	[MM]	[HM]	[MM]
9	2,51	2,06	1,86		[MM BM]	[HM]	[MM BM]	[HM]
10	1,65	1,28	1,17		[MM BM]	[HM]	[MM BM]	[HM]
11	1,30	1,13	0,93		[MM]	[BM HM]	[MM]	[BM HM]
12	1,55	1,49	1,27		[MM]	[BM HM]	[MM]	[BM HM]
13	3,78	3,48	3,51		[BM MM]	[HM]	[BM MM]	[HM]
14	3,41	3,13	2,94		[MM BM]	[HM]	[MM BM]	[HM]
15	3,20	3,01	2,99		[MM BM]	[HM]	[MM BM]	[HM]
16	3,47	3,23	3,24		[BM MM]	[HM]	[BM MM]	[HM]
17	2,71	1,97	2,01		[BM MM]	[HM]	[BM MM]	[HM]
18	1,92	1,61	1,45		[MM BM]	[HM]	[MM BM]	[HM]
19	1,76	1,63	1,51		[MM BM]	[HM]	[MM BM]	[HM]
20	1,96	2,03	1,85		[MM HM]	[BM]	[MM HM]	[BM]

Tab. D.9: Podsumowanie wyników jednoczynnikowej analizy wariancji dla ζ w $\mathbb{G}_A$. Wielkość próby w każdej komórce wynosi $n = 270$.

#	$\tilde{\mathcal{P}}$	$g_{\max}$	E	α	p_α	Parametry $\mathcal{G}_A$			df1	Test Levene'a			Test ANOVA			Test Welch'a			Test Brown-Forsythe'a		
						β	p_β	ζ		df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_w	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	50	400	−	MIX	0,90	MM	0,10	★	2	807	7,08	<0,001	807	73,07	<0,001	533	66,24	<0,001	783	73,07	<0,001
2	100	200	−	MIX	0,90	MM	0,10	★	2	807	21,87	<0,001	807	126,02	<0,001	527	100,60	<0,001	712	126,02	<0,001
3	200	100	−	MIX	0,90	MM	0,10	★	2	807	16,40	<0,001	807	125,17	<0,001	526	111,63	<0,001	724	125,17	<0,001
4	50	400	+	MIX	0,90	MM	0,10	★	2	807	6,78	0,001	807	2,45	0,087	533	2,21	0,111	774	2,45	0,087
5	100	200	+	MIX	0,90	MM	0,10	★	2	807	0,09	0,913	807	7,23	<0,001	538	7,07	<0,001	806	7,23	<0,001
6	200	100	+	MIX	0,90	MM	0,10	★	2	807	10,36	<0,001	807	58,17	<0,001	527	47,49	<0,001	712	58,17	<0,001

Tab. D.10: Podsumowanie wyników testów *post-hoc* dla ζ w $\mathbb{G}_A$. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów $\mathbb{G}_A$ dla poniższych porównań przedstawiono w tab. D.9 (zgodnie z oznaczeniem w #).

#	Wartość $\overline{\epsilon}[\%]$ dla ζ				Grupy jednorodne według ζ			
	2	3	4		Tukey (HSD)	Tamhane (T2)	Games-Howell (GH)	
1	3,98	2,66	2,53		[4 3] [2]	[4 3] [2]	[4 3] [2]	
2	2,97	1,70	1,55		[4 3] [2]	[4 3] [2]	[4 3] [2]	
3	2,58	1,56	1,13		[4] [3] [2]	[4] [3] [2]	[4] [3] [2]	
4	2,01	2,06	2,26		[2 3 4]	[2 3 4]	[2 3 4]	
5	1,45	1,17	1,18		[3 4] [2]	[3 4] [2]	[3 4] [2]	
6	1,51	0,93	0,78		[4 3] [2]	[4 3] [2]	[4 3] [2]	

Tab. D.11: Podsumowanie wyników jednoczynnikowej analizy wariancji dla p_α w GA. Wielkość próby w każdej komórce wynosi $n = 270$.

#	$\hat{\mathcal{P}}$	$g_{\max}$	E	α	p_α	Parametry GA			df1	Test Levene'a			Test ANOVA			Test Welch'a			Test Brown-Forsythe'a		
						β	p_β	ζ		df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_W	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	200	100	+	2PX	★	HM	0,10	2	4	1345	30,11	<0,001	1345	109,71	<0,001	667	64,84	<0,001	983	109,71	<0,001
2	200	100	+	2PX	★	BM	0,10	2	4	1345	46,09	<0,001	1345	99,80	<0,001	665	61,10	<0,001	928	99,80	<0,001
3	200	100	+	2PX	★	MM	0,10	2	4	1345	50,92	<0,001	1345	135,27	<0,001	666	79,80	<0,001	906	135,27	<0,001
4	200	100	+	MIX	★	HM	0,10	2	4	1345	12,27	<0,001	1345	54,07	<0,001	669	36,68	<0,001	1171	54,07	<0,001
5	200	100	+	MIX	★	BM	0,10	2	4	1345	15,72	<0,001	1345	37,36	<0,001	670	24,60	<0,001	1174	37,36	<0,001
6	200	100	+	MIX	★	MM	0,10	2	4	1345	19,93	<0,001	1345	42,24	<0,001	669	27,79	<0,001	1147	42,24	<0,001
7	200	100	+	2PX	★	HM	0,02	2	4	1345	26,53	<0,001	1345	124,16	<0,001	667	97,90	<0,001	1132	124,16	<0,001
8	200	100	+	2PX	★	BM	0,02	2	4	1345	60,41	<0,001	1345	146,41	<0,001	663	88,34	<0,001	825	146,41	<0,001
9	200	100	+	2PX	★	MM	0,02	2	4	1345	48,45	<0,001	1345	138,80	<0,001	667	90,60	<0,001	969	138,80	<0,001
10	200	100	+	MIX	★	HM	0,02	2	4	1345	24,68	<0,001	1345	94,96	<0,001	667	63,33	<0,001	1073	94,96	<0,001
11	200	100	+	MIX	★	BM	0,02	2	4	1345	63,93	<0,001	1345	140,75	<0,001	665	79,40	<0,001	911	140,75	<0,001
12	200	100	+	MIX	★	MM	0,02	2	4	1345	35,18	<0,001	1345	107,19	<0,001	668	62,58	<0,001	996	107,19	<0,001

Tab. D.12: Podsumowanie wyników testów *post-hoc* dla p_α w GA. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów GA dla poniższych porównań przedstawiono w tab. D.11 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}$ [%] dla p_α					Grupy jednorodne według p_α											
	0,10	0,30	0,50	0,70	0,90	Tukey (HSD)				Tamhane (T2)				Games-Howell (GH)			
1	3,38	1,87	1,49	1,38	1,30	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]
2	2,44	1,59	1,22	1,17	1,13	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]
3	2,43	1,41	1,12	0,99	0,93	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]
4	3,15	1,92	1,66	1,67	1,77	[0,50 0,70 0,90 0,30]	[0,10]	[0,50 0,70 0,90 0,30]	[0,10]	[0,50 0,70 0,90 0,30]	[0,10]	[0,50 0,70 0,90 0,30]	[0,10]	[0,50 0,70 0,90 0,30]	[0,10]	[0,50 0,70 0,90 0,30]	[0,10]
5	2,33	1,58	1,45	1,52	1,63	[0,50 0,70 0,30 0,90]	[0,10]	[0,50 0,70 0,30 0,90]	[0,10]	[0,50 0,70 0,30 0,90]	[0,10]	[0,50 0,70 0,30 0,90]	[0,10]	[0,50 0,70 0,30 0,90]	[0,10]	[0,50 0,70 0,30 0,90]	[0,10]
6	2,31	1,47	1,31	1,36	1,51	[0,50 0,70 0,30 0,90]	[0,10]	[0,50 0,70 0,30 0,90]	[0,10]	[0,50 0,70 0,30 0,90]	[0,10]	[0,50 0,70 0,30 0,90]	[0,10]	[0,50 0,70 0,30 0,90]	[0,10]	[0,50 0,70 0,30 0,90]	[0,10]
7	4,26	2,79	2,11	1,84	1,51	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]
8	2,93	1,61	1,10	0,97	0,83	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]
9	2,99	1,67	1,26	1,02	0,88	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]	[0,90 0,70 0,50]	[0,30]	[0,10]
10	4,29	2,58	2,03	1,79	1,85	[0,70 0,90 0,50]	[0,30]	[0,10]	[0,70 0,90 0,50]	[0,30]	[0,10]	[0,70 0,90 0,50]	[0,30]	[0,10]	[0,70 0,90 0,50]	[0,30]	[0,10]
11	3,04	1,55	1,11	1,00	1,12	[0,70 0,50 0,90]	[0,30]	[0,10]	[0,70 0,50 0,90]	[0,30]	[0,10]	[0,70 0,50 0,90]	[0,30]	[0,10]	[0,70 0,50 0,90]	[0,30]	[0,10]
12	2,99	1,59	1,26	1,11	1,18	[0,70 0,90 0,50]	[0,30]	[0,10]	[0,70 0,90 0,50]	[0,30]	[0,10]	[0,70 0,90 0,50]	[0,30]	[0,10]	[0,70 0,90 0,50]	[0,30]	[0,10]

Tab. D.13: Podsumowanie wyników jednoczynnikowej analizy wariancji dla p_β w $\mathbb{G}_A$. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry $\mathbb{G}_A$					Test Levene'a			Test ANOVA			Test Welch'a			Test Browna-Forsythe'a						
	$\mathcal{P}$	$g_{\max}$	E	α	p_α	β	p_β	ζ	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_W	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	200	100	+	2PX	0,10	HM	★	2	6	1883	12,45	<0,001	1883	14,42	<0,001	834	16,30	<0,001	1734	14,42	<0,001
2	200	100	+	2PX	0,30	HM	★	2	6	1883	13,81	<0,001	1883	14,88	<0,001	834	13,63	<0,001	1688	14,88	<0,001
3	200	100	+	2PX	0,50	HM	★	2	6	1883	9,33	<0,001	1883	14,37	<0,001	835	16,89	<0,001	1748	14,37	<0,001
4	200	100	+	2PX	0,70	HM	★	2	6	1883	9,29	<0,001	1883	17,66	<0,001	835	21,54	<0,001	1732	17,66	<0,001
5	200	100	+	2PX	0,90	HM	★	2	6	1883	1,55	0,160	1883	25,10	<0,001	836	28,06	<0,001	1842	25,10	<0,001
6	200	100	+	MIX	0,10	HM	★	2	6	1883	16,51	<0,001	1883	17,32	<0,001	831	16,56	<0,001	1642	17,32	<0,001
7	200	100	+	MIX	0,30	HM	★	2	6	1883	11,24	<0,001	1883	8,24	<0,001	834	9,15	<0,001	1688	8,24	<0,001
8	200	100	+	MIX	0,50	HM	★	2	6	1883	4,08	<0,001	1883	11,40	<0,001	835	14,48	<0,001	1741	11,40	<0,001
9	200	100	+	MIX	0,70	HM	★	2	6	1883	2,31	0,031	1883	12,73	<0,001	836	15,31	<0,001	1819	12,73	<0,001
10	200	100	+	MIX	0,90	HM	★	2	6	1883	2,87	0,009	1883	10,24	<0,001	836	12,67	<0,001	1823	10,24	<0,001
11	200	100	+	2PX	0,10	BM	★	2	6	1883	5,12	<0,001	1883	32,90	<0,001	836	35,97	<0,001	1785	32,90	<0,001
12	200	100	+	2PX	0,30	BM	★	2	6	1883	8,40	<0,001	1883	148,83	<0,001	836	120,59	<0,001	1768	148,83	<0,001
13	200	100	+	2PX	0,50	BM	★	2	6	1883	28,94	<0,001	1883	289,65	<0,001	834	194,99	<0,001	1504	289,65	<0,001
14	200	100	+	2PX	0,70	BM	★	2	6	1883	32,75	<0,001	1883	335,35	<0,001	834	225,71	<0,001	1512	335,35	<0,001
15	200	100	+	2PX	0,90	BM	★	2	6	1883	40,80	<0,001	1883	376,17	<0,001	833	234,76	<0,001	1399	376,17	<0,001
16	200	100	+	MIX	0,10	BM	★	2	6	1883	7,83	<0,001	1883	35,78	<0,001	836	38,50	<0,001	1802	35,78	<0,001
17	200	100	+	MIX	0,30	BM	★	2	6	1883	11,30	<0,001	1883	166,68	<0,001	836	136,05	<0,001	1748	166,68	<0,001
18	200	100	+	MIX	0,50	BM	★	2	6	1883	17,80	<0,001	1883	233,49	<0,001	835	171,63	<0,001	1652	233,49	<0,001
19	200	100	+	MIX	0,70	BM	★	2	6	1883	23,20	<0,001	1883	238,65	<0,001	835	164,63	<0,001	1565	238,65	<0,001
20	200	100	+	MIX	0,90	BM	★	2	6	1883	13,05	<0,001	1883	192,65	<0,001	835	143,24	<0,001	1693	192,65	<0,001
21	200	100	+	2PX	0,10	MM	★	2	6	1883	7,37	<0,001	1883	15,83	<0,001	836	18,06	<0,001	1789	15,83	<0,001
22	200	100	+	2PX	0,30	MM	★	2	6	1883	5,76	<0,001	1883	87,71	<0,001	836	78,52	<0,001	1819	87,71	<0,001
23	200	100	+	2PX	0,50	MM	★	2	6	1883	9,45	<0,001	1883	152,55	<0,001	835	126,70	<0,001	1765	152,55	<0,001
24	200	100	+	2PX	0,70	MM	★	2	6	1883	10,26	<0,001	1883	204,93	<0,001	835	164,66	<0,001	1704	204,93	<0,001
25	200	100	+	2PX	0,90	MM	★	2	6	1883	20,65	<0,001	1883	231,50	<0,001	834	158,65	<0,001	1583	231,50	<0,001
26	200	100	+	MIX	0,10	MM	★	2	6	1883	5,35	<0,001	1883	18,67	<0,001	836	20,25	<0,001	1790	18,67	<0,001
27	200	100	+	MIX	0,30	MM	★	2	6	1883	3,32	0,003	1883	91,06	<0,001	836	80,66	<0,001	1837	91,06	<0,001
28	200	100	+	MIX	0,50	MM	★	2	6	1883	6,01	<0,001	1883	137,76	<0,001	836	118,61	<0,001	1790	137,76	<0,001
29	200	100	+	MIX	0,70	MM	★	2	6	1883	7,28	<0,001	1883	133,63	<0,001	836	102,83	<0,001	1769	133,63	<0,001
30	200	100	+	MIX	0,90	MM	★	2	6	1883	6,37	<0,001	1883	113,90	<0,001	836	93,99	<0,001	1811	113,90	<0,001

Tab. D.14: Podsumowanie wyników testów *post-hoc* dla p_β w $\mathbb{G}\mathbb{A}$. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów $\mathbb{G}\mathbb{A}$ dla poniższych porównań przedstawiono w tab. D.13 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla $p_\beta =$					Grupy jednorodne według p_β				
	0,02	0,04	0,06	0,08	0,10	Tukey (HSD)		Tamhane (T2)	Games-Howell (GH)	
1	4,26	3,78	3,61	3,51	3,38	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]
2	2,79	2,31	2,06	2,00	1,87	[0,10 0,08 0,06 0,04] [0,02]	[0,10 0,08 0,06 0,04] [0,02]	[0,10 0,08 0,06 0,04] [0,02]	[0,10 0,08 0,06 0,04] [0,02]	[0,10 0,08 0,06 0,04] [0,02]
3	2,11	1,80	1,61	1,60	1,49	[0,10 0,08 0,06 0,04] [0,02]	[0,10 0,08 0,06 0,04] [0,02]	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]
4	1,84	1,58	1,34	1,44	1,38	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]
5	1,51	1,39	1,29	1,31	1,30	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]
6	4,29	3,64	3,43	3,21	3,15	[0,10 0,08 0,06 0,04] [0,02]	[0,10 0,08 0,06 0,04] [0,02]	[0,10 0,08 0,06 0,04] [0,02]	[0,10 0,08 0,06 0,04] [0,02]	[0,10 0,08 0,06 0,04] [0,02]
7	2,58	2,25	2,11	2,03	1,92	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]
8	2,03	1,82	1,65	1,66	1,66	[0,06 0,08 0,10 0,04] 0,02]	[0,06 0,08 0,10 0,04] 0,02]	[0,06 0,08 0,10 0,04] 0,02]	[0,06 0,08 0,10 0,04] 0,02]	[0,06 0,08 0,10 0,04] 0,02]
9	1,79	1,78	1,65	1,56	1,67	[0,08 0,06 0,10 0,04] 0,02]	[0,08 0,06 0,10 0,04] 0,02]	[0,08 0,06 0,10 0,04] 0,02]	[0,08 0,06 0,10 0,04] 0,02]	[0,08 0,06 0,10 0,04] 0,02]
10	1,85	1,76	1,67	1,75	1,77	[0,06 0,08 0,04 0,10] 0,02]	[0,06 0,08 0,04 0,10] 0,02]	[0,06 0,08 0,04 0,10] 0,02]	[0,06 0,08 0,04 0,10] 0,02]	[0,06 0,08 0,04 0,10] 0,02]
11	2,93	2,53	2,36	2,47	2,44	[0,06 0,10 0,08 0,04] [0,02]	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]
12	1,61	1,38	1,40	1,46	1,59	[0,04 0,06 0,08 0,10] 0,02]	[0,04 0,06 0,08 0,10] 0,02]	[0,04 0,06 0,08 0,10] 0,02]	[0,04 0,06 0,08 0,10] 0,02]	[0,04 0,06 0,08 0,10] 0,02]
13	1,10	0,99	0,99	1,09	1,22	[0,06 0,04 0,08 0,02] 0,10]	[0,06 0,04 0,08 0,02] 0,10]	[0,06 0,04 0,08 0,02] 0,10]	[0,06 0,04 0,08 0,02] 0,10]	[0,06 0,04 0,08 0,02] 0,10]
14	0,97	0,85	0,89	1,03	1,17	[0,04 0,06 0,02 0,08] 0,10]	[0,04 0,06 0,02] [0,08] 0,10]	[0,04 0,06 0,02] [0,08] 0,10]	[0,04 0,06 0,02] [0,08] 0,10]	[0,04 0,06 0,02] [0,08] 0,10]
15	0,83	0,78	0,88	1,02	1,13	[0,04 0,02 0,06] [0,08] 0,10]	[0,04 0,02 0,06] [0,08] 0,10]	[0,04 0,02 0,06] [0,08] 0,10]	[0,04 0,02 0,06] [0,08] 0,10]	[0,04 0,02 0,06] [0,08] 0,10]
16	3,04	2,39	2,45	2,40	2,33	[0,10 0,04 0,08 0,06] [0,02]	[0,10 0,04 0,08 0,06] [0,02]	[0,10 0,04 0,08 0,06] [0,02]	[0,10 0,04 0,08 0,06] [0,02]	[0,10 0,04 0,08 0,06] [0,02]
17	1,55	1,31	1,39	1,57	1,58	[0,04 0,06 0,02 0,08] 0,10]	[0,04 0,06 0,02 0,08] 0,10]	[0,04 0,06 0,02 0,08] 0,10]	[0,04 0,06 0,02 0,08] 0,10]	[0,04 0,06 0,02 0,08] 0,10]
18	1,11	1,11	1,18	1,34	1,45	[0,04 0,02 0,06 0,08] 0,10]	[0,04 0,02 0,06] [0,08] 0,10]	[0,04 0,02 0,06] [0,08] 0,10]	[0,04 0,02 0,06] [0,08] 0,10]	[0,04 0,02 0,06] [0,08] 0,10]
19	1,00	1,17	1,22	1,37	1,52	[0,02 0,04 0,06] [0,08] 0,10]	[0,02 0,04] 0,06 [0,08] 0,10]	[0,02 0,04] 0,06 [0,08] 0,10]	[0,02 0,04] 0,06 [0,08] 0,10]	[0,02 0,04] 0,06 [0,08] 0,10]
20	1,12	1,27	1,40	1,51	1,63	[0,02 0,04] [0,06 0,08] 0,10]	[0,02 0,04] 0,06 [0,08] 0,10]	[0,02 0,04] 0,06 [0,08] 0,10]	[0,02 0,04] [0,06] [0,08] 0,10]	[0,02 0,04] [0,06] [0,08] 0,10]
21	2,99	2,72	2,41	2,47	2,43	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]	[0,06 0,10 0,08 0,04] 0,02]
22	1,67	1,42	1,37	1,47	1,41	[0,06 0,10 0,04 0,08] 0,02]	[0,06 0,10 0,04 0,08] 0,02]	[0,06 0,10 0,04 0,08] 0,02]	[0,06 0,10 0,04 0,08] 0,02]	[0,06 0,10 0,04 0,08] 0,02]
23	1,26	1,00	1,05	1,08	1,12	[0,04 0,06 0,08 0,10] 0,02]	[0,04 0,06 0,08 0,10] 0,02]	[0,04 0,06 0,08 0,10] 0,02]	[0,04 0,06 0,08 0,10] 0,02]	[0,04 0,06 0,08 0,10] 0,02]
24	1,02	0,88	0,90	0,96	0,99	[0,04 0,06 0,08 0,10] 0,02]	[0,04 0,06 0,08 0,10] 0,02]	[0,04 0,06 0,08 0,10] 0,02]	[0,04 0,06 0,08 0,10] 0,02]	[0,04 0,06 0,08 0,10] 0,02]
25	0,88	0,84	0,88	0,89	0,93	[0,04 0,02 0,06 0,08] 0,10]	[0,04 0,02 0,06 0,08] 0,10]	[0,04 0,02 0,06 0,08] 0,10]	[0,04 0,02 0,06 0,08] 0,10]	[0,04 0,02 0,06 0,08] 0,10]
26	2,99	2,68	2,52	2,37	2,31	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]	[0,10 0,08 0,06 0,04] 0,02]
27	1,59	1,41	1,38	1,37	1,47	[0,08 0,06 0,04 0,10] 0,02]	[0,08 0,06 0,04 0,10] 0,02]	[0,08 0,06 0,04 0,10] 0,02]	[0,08 0,06 0,04 0,10] 0,02]	[0,08 0,06 0,04 0,10] 0,02]
28	1,26	1,08	1,12	1,22	1,31	[0,04 0,06 0,08 0,02] 0,10]	[0,04 0,06 0,08 0,02] 0,10]	[0,04 0,06 0,08 0,02] 0,10]	[0,04 0,06 0,08 0,02] 0,10]	[0,04 0,06 0,08 0,02] 0,10]
29	1,11	1,11	1,25	1,30	1,36	[0,02 0,04 0,06 0,08] 0,10]	[0,02 0,04 0,06 0,08] 0,10]	[0,02 0,04 0,06 0,08] 0,10]	[0,02 0,04 0,06 0,08] 0,10]	[0,02 0,04 0,06 0,08] 0,10]
30	1,18	1,23	1,33	1,42	1,51	[0,02 0,04 0,06 0,08] 0,10]	[0,02 0,04 0,06 0,08] 0,10]	[0,02 0,04 0,06 0,08] 0,10]	[0,02 0,04 0,06 0,08] 0,10]	[0,02 0,04 0,06 0,08] 0,10]

Tab. D.15: Podsumowanie wyników jednoczynnikowej analizy wariancji dla elityzmu w GA. Wielkość próby w każdej komórce wynosi $n = 270$.

#	$\mathcal{P}$	$g_{\max}$	E	Parametry GA				$\overline{\epsilon}[\%]$ dla E		df1	Test Levene'a			Test ANOVA			Test Welch'a			
				α	p_{α}	β	p_{β}	ζ	-		+	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_w	$p(H_0)$
1	200	100	★	1PX	0,90	HMI	0,10	2	2,27	1,77	1	538	3,59	0,059	538	19,41	<0,001	528	19,41	<0,001
2	200	100	★	PSX	0,90	HMI	0,10	2	2,81	1,52	1	538	45,44	<0,001	538	86,09	<0,001	445	86,09	<0,001
3	200	100	★	2PX	0,90	HMI	0,10	2	1,77	1,30	1	538	1,43	0,232	538	27,39	<0,001	537	27,39	<0,001
4	200	100	★	UX	0,90	HMI	0,10	2	4,10	3,20	1	538	3,14	0,077	538	21,46	<0,001	513	21,46	<0,001
5	200	100	★	MIX	0,90	HMI	0,10	2	2,33	1,76	1	538	2,94	0,087	538	18,82	<0,001	537	18,82	<0,001
6	200	100	★	1PX	0,90	BM	0,10	2	2,85	1,53	1	538	33,34	<0,001	538	188,19	<0,001	450	188,19	<0,001
7	200	100	★	PSX	0,90	BM	0,10	2	6,28	2,38	1	538	132,61	<0,001	538	392,32	<0,001	386	392,32	<0,001
8	200	100	★	2PX	0,90	BM	0,10	2	2,32	1,13	1	538	32,33	<0,001	538	270,50	<0,001	454	270,50	<0,001
9	200	100	★	UX	0,90	BM	0,10	2	4,42	3,01	1	538	9,13	0,003	538	81,99	<0,001	519	81,99	<0,001
10	200	100	★	MIX	0,90	BM	0,10	2	3,11	1,63	1	538	31,15	<0,001	538	226,09	<0,001	459	226,09	<0,001
11	200	100	★	1PX	0,90	MM	0,10	2	2,40	1,42	1	538	13,75	<0,001	538	109,00	<0,001	492	109,00	<0,001
12	200	100	★	PSX	0,90	MM	0,10	2	4,92	1,93	1	538	110,04	<0,001	538	274,74	<0,001	376	274,74	<0,001
13	200	100	★	2PX	0,90	MM	0,10	2	1,70	0,93	1	538	15,83	<0,001	538	133,01	<0,001	488	133,01	<0,001
14	200	100	★	UX	0,90	MM	0,10	2	3,98	2,99	1	538	6,53	0,011	538	37,71	<0,001	522	37,71	<0,001
15	200	100	★	MIX	0,90	MM	0,10	2	2,58	1,51	1	538	16,32	<0,001	538	108,90	<0,001	508	108,90	<0,001
16	100	200	★	1PX	0,90	HMI	0,10	2	2,71	2,45	1	538	0,68	0,410	538	3,30	0,070	536	3,30	0,070
17	100	200	★	PSX	0,90	HMI	0,10	2	2,69	1,60	1	538	14,93	<0,001	538	71,04	<0,001	504	71,04	<0,001
18	100	200	★	2PX	0,90	HMI	0,10	2	2,11	1,65	1	538	1,11	0,292	538	15,59	<0,001	538	15,59	<0,001
19	100	200	★	UX	0,90	HMI	0,10	2	4,72	3,41	1	538	6,49	0,011	538	38,04	<0,001	517	38,04	<0,001
20	100	200	★	MIX	0,90	HMI	0,10	2	2,54	1,92	1	538	3,76	0,053	538	26,24	<0,001	523	26,24	<0,001
21	100	200	★	1PX	0,90	BM	0,10	2	3,52	1,75	1	538	23,81	<0,001	538	247,81	<0,001	475	247,81	<0,001
22	100	200	★	PSX	0,90	BM	0,10	2	6,79	1,96	1	538	181,31	<0,001	538	598,54	<0,001	343	598,54	<0,001
23	100	200	★	2PX	0,90	BM	0,10	2	2,78	1,28	1	538	23,27	<0,001	538	312,01	<0,001	489	312,01	<0,001
24	100	200	★	UX	0,90	BM	0,10	2	5,19	3,13	1	538	16,22	<0,001	538	151,03	<0,001	507	151,03	<0,001
25	100	200	★	MIX	0,90	BM	0,10	2	3,62	1,61	1	538	42,89	<0,001	538	373,62	<0,001	454	373,62	<0,001
26	100	200	★	1PX	0,90	MM	0,10	2	2,81	1,61	1	538	7,84	0,005	538	135,95	<0,001	522	135,95	<0,001
27	100	200	★	PSX	0,90	MM	0,10	2	5,13	1,74	1	538	133,64	<0,001	538	374,92	<0,001	381	374,92	<0,001
28	100	200	★	2PX	0,90	MM	0,10	2	2,11	1,17	1	538	15,69	<0,001	538	125,93	<0,001	492	125,93	<0,001
29	100	200	★	UX	0,90	MM	0,10	2	4,81	2,94	1	538	34,56	<0,001	538	123,83	<0,001	471	123,83	<0,001
30	100	200	★	MIX	0,90	MM	0,10	2	2,96	1,45	1	538	28,18	<0,001	538	211,24	<0,001	485	211,24	<0,001
31	400	50	★	1PX	0,90	HMI	0,10	2	2,37	2,00	1	538	0,06	0,800	538	10,30	0,001	536	10,30	0,001

Tab. D.15: Podsumowanie wyników jednoczynnikowej analizy wariancji dla elityzmu w GA (c.d.)

#	$\mathcal{P}$	$g_{\max}$	E	Parametry GA				$\bar{\epsilon}[\%]$ dla E		df1	Test Levene'a		Test ANOVA		Test Welch'a					
				α	p_{α}	β	p_{β}	ζ	-		+	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_w	$p(H_0)$
32	400	50	★	PSX	0,90	HMI	0,10	2	3,24	1,94	1	538	42,86	<0,001	538	85,65	<0,001	455	85,65	<0,001
33	400	50	★	2PX	0,90	HMI	0,10	2	1,83	1,55	1	538	2,24	0,135	538	9,21	0,003	533	9,21	0,003
34	400	50	★	UX	0,90	HMI	0,10	2	4,10	3,47	1	538	2,02	0,156	538	10,93	0,001	535	10,93	0,001
35	400	50	★	MIX	0,90	HMI	0,10	2	2,55	1,96	1	538	10,02	0,002	538	22,18	<0,001	510	22,18	<0,001
36	400	50	★	1PX	0,90	BM	0,10	2	2,83	1,87	1	538	25,87	<0,001	538	103,43	<0,001	488	103,43	<0,001
37	400	50	★	PSX	0,90	BM	0,10	2	5,66	2,77	1	538	102,51	<0,001	538	256,29	<0,001	403	256,29	<0,001
38	400	50	★	2PX	0,90	BM	0,10	2	2,30	1,49	1	538	12,85	<0,001	538	122,05	<0,001	503	122,05	<0,001
39	400	50	★	UX	0,90	BM	0,10	2	4,18	3,23	1	538	5,92	0,015	538	36,23	<0,001	525	36,23	<0,001
40	400	50	★	MIX	0,90	BM	0,10	2	2,99	2,03	1	538	15,88	<0,001	538	91,98	<0,001	503	91,98	<0,001
41	400	50	★	1PX	0,90	MM	0,10	2	2,40	1,74	1	538	8,35	0,004	538	49,31	<0,001	513	49,31	<0,001
42	400	50	★	PSX	0,90	MM	0,10	2	4,79	2,46	1	538	67,49	<0,001	538	178,41	<0,001	429	178,41	<0,001
43	400	50	★	2PX	0,90	MM	0,10	2	1,86	1,27	1	538	7,72	0,006	538	70,80	<0,001	516	70,80	<0,001
44	400	50	★	UX	0,90	MM	0,10	2	3,92	3,24	1	538	2,45	0,118	538	17,85	<0,001	528	17,85	<0,001
45	400	50	★	MIX	0,90	MM	0,10	2	2,64	1,85	1	538	7,98	0,005	538	61,29	<0,001	522	61,29	<0,001

Tab. D.16: Podsumowanie wyników jednoczynnikowej analizy wariancji dla β w SA. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry SA						Test Levene'a		Test ANOVA		Test Welch'a		Test Browna-Forsythe'a								
	β	p_p	p_m	C	S	N	$\Delta_{\max}$	h	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_{BF}	$p(H_0)$			
1	★	0,90	0,02	1	5	1973	0,2	0	2	807	45,88	<0,001	807	32,07	<0,001	461	50,76	<0,001	634	32,07	<0,001
2	★	0,90	0,02	2	5	989	0,2	0	2	807	43,81	<0,001	807	38,78	<0,001	464	61,08	<0,001	633	38,78	<0,001
3	★	0,90	0,02	3	5	659	0,2	0	2	807	54,37	<0,001	807	45,11	<0,001	472	68,83	<0,001	651	45,11	<0,001
4	★	0,90	0,02	4	5	494	0,2	0	2	807	42,60	<0,001	807	43,78	<0,001	439	73,66	<0,001	588	43,78	<0,001
5	★	0,90	0,02	5	5	396	0,2	0	2	807	61,57	<0,001	807	59,98	<0,001	417	106,72	<0,001	570	59,98	<0,001
6	★	0,90	0,02	6	5	330	0,2	0	2	807	64,89	<0,001	807	58,44	<0,001	409	105,00	<0,001	569	58,44	<0,001
7	★	0,90	0,02	7	5	283	0,2	0	2	807	53,16	<0,001	807	58,16	<0,001	428	100,22	<0,001	596	58,16	<0,001
8	★	0,90	0,02	8	5	248	0,2	0	2	807	66,65	<0,001	807	71,90	<0,001	435	121,65	<0,001	596	71,90	<0,001
9	★	0,90	0,02	9	5	220	0,2	0	2	807	59,98	<0,001	807	68,05	<0,001	436	114,46	<0,001	607	68,05	<0,001
10	★	0,90	0,02	10	5	199	0,2	0	2	807	61,01	<0,001	807	73,16	<0,001	420	127,45	<0,001	590	73,16	<0,001

Tab. D.17: Podsumowanie wyników testów *post-hoc* dla β w SA. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów SA dla poniższych porównań przedstawiono w tab. D.16 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla β			Grupy jednorodne według β					
	HM	BM	MM	Tukey (HSD)		Tamhane (T2)		Games-Howell (GH)	
1	1,55	0,60	1,48	[BM]	[MM HM]	[BM]	[MM HM]	[BM]	[MM HM]
2	1,22	0,45	1,21	[BM]	[MM HM]	[BM]	[MM HM]	[BM]	[MM HM]
3	1,24	0,45	1,25	[BM]	[HM MM]	[BM]	[HM MM]	[BM]	[HM MM]
4	1,41	0,47	1,32	[BM]	[MM HM]	[BM]	[MM HM]	[BM]	[MM HM]
5	1,43	0,42	1,36	[BM]	[MM HM]	[BM]	[MM HM]	[BM]	[MM HM]
6	1,49	0,44	1,40	[BM]	[MM HM]	[BM]	[MM HM]	[BM]	[MM HM]
7	1,51	0,50	1,49	[BM]	[MM HM]	[BM]	[MM HM]	[BM]	[MM HM]
8	1,47	0,51	1,54	[BM]	[HM MM]	[BM]	[HM MM]	[BM]	[HM MM]
9	1,60	0,56	1,61	[BM]	[HM MM]	[BM]	[HM MM]	[BM]	[HM MM]
10	1,61	0,55	1,70	[BM]	[HM MM]	[BM]	[HM MM]	[BM]	[HM MM]

Tab. D.18: Podsumowanie wyników jednoczynnikowej analizy wariancji dla C w $\mathbb{S}\mathbb{A}$. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry $\mathbb{S}\mathbb{A}$										Test Levene'a			Test ANOVA		Test Welch'a			Test Browna-Forsythe'a		
	β	p_p	p_n	C	S	N	$\Delta_{\max}$	h	df1	df2	L	$p(H_0)$	df2	F	df2	F_w	$p(H_0)$	df2	F_{BF}	$p(H_0)$	
1	BM	0,90	0,02	★	3	★	0,2	0	9	2690	1,98	0,038	2690	7,53	<0,001	1095	7,59	<0,001	2555	7,53	<0,001
2	BM	0,90	0,02	★	5	★	0,2	0	9	2690	6,68	<0,001	2690	3,31	<0,001	1094	3,25	<0,001	2288	3,31	<0,001
3	BM	0,90	0,02	★	10	★	0,2	0	9	2690	36,23	<0,001	2690	23,60	<0,001	1093	15,05	<0,001	1804	23,60	<0,001
4	HM	0,90	0,02	★	5	★	0,2	0	9	2690	1,92	0,044	2690	2,21	0,019	1095	2,46	0,009	2586	2,21	0,019
5	MM	0,90	0,02	★	5	★	0,2	0	9	2690	3,06	0,001	2690	3,19	<0,001	1096	3,43	<0,001	2563	3,19	<0,001

Tab. D.19: Podsumowanie wyników testów *post-hoc* dla C w $\mathbb{S}\mathbb{A}$. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów $\mathbb{S}\mathbb{A}$ dla poniższych porównań przedstawiono w tab. D.18 (zgodnie z oznaczeniem w #).

#	Wartość $\overline{\epsilon}[\%]$ dla $C =$									
	1	2	3	4	5	6	7	8	9	10
1	1,26	1,18	1,23	1,24	1,31	1,28	1,40	1,36	1,46	1,45
2	0,60	0,45	0,45	0,47	0,42	0,44	0,50	0,51	0,56	0,55
3	1,47	1,28	1,02	0,86	0,87	0,78	0,73	0,74	0,68	0,69
4	1,55	1,22	1,24	1,41	1,43	1,49	1,51	1,47	1,60	1,61
5	1,48	1,21	1,25	1,32	1,36	1,40	1,49	1,54	1,61	1,70

#	Tukey (HSD)			Tamhane (T2)			Grupy jednorodne według <i>C</i>		
							Games-Howell (GH)		
1	[2 3 4 1 6 5 8]	7 10 9]		[2 3 4 1 6 5 8]	7 10 9]		[2 3 4 1 6 5 8]	7 10 9]	
2	[5 6 2 3 4 7 8 10 9]	1]		[5 6 2 3 4 7 8 10 9]	1]		[5 6 2 3 4 7 8 10 9]	1]	
3	[9 10 7 8 6 4 5]	3]	[2 1]	[9 10 7 8 6 4 5]	3]	[2 1]	[9 10 7 8 6 4 5]	3]	[2 1]
4	[2 3 4 5 8 6 7 1 9 10]			[2 3 4 5 8 6 7 1 9 10]			[2 3 4 5 8 6 7 1 9 10]		
5	[2 3 4 5 6 1 7 8 9]	10]		[2 3 4 5 6 1 7 8 9]	10]		[2 3 4 5 6 1 7 8 9]	10]	

Tab. D.21: Podsumowanie wyników jednoczynnikowej analizy wariancji dla S w $\mathbb{S}_A$. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry $\mathbb{S}_A$						Test Levene'a			Test ANOVA			Test Welch'a			Test Browna-Forsythe'a		
	β	p_p	p_m	C	S	N	$\Delta_{\max}$	h	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	BM	0,90	0,02	1	*	*	0,2	0	2	807	60,47	<0,001	807	49,40	<0,001	509	64,51	<0,001
2	BM	0,90	0,02	2	*	*	0,2	0	2	807	72,23	<0,001	807	73,71	<0,001	505	120,33	<0,001
3	BM	0,90	0,02	3	*	*	0,2	0	2	807	32,00	<0,001	807	79,35	<0,001	525	107,43	<0,001
4	BM	0,90	0,02	4	*	*	0,2	0	2	807	15,07	<0,001	807	101,20	<0,001	525	138,33	<0,001
5	BM	0,90	0,02	5	*	*	0,2	0	2	807	40,66	<0,001	807	136,63	<0,001	511	229,73	<0,001
6	BM	0,90	0,02	6	*	*	0,2	0	2	807	25,40	<0,001	807	139,66	<0,001	513	214,89	<0,001
7	BM	0,90	0,02	7	*	*	0,2	0	2	807	8,24	<0,001	807	175,03	<0,001	531	201,44	<0,001
8	BM	0,90	0,02	8	*	*	0,2	0	2	807	10,21	<0,001	807	163,37	<0,001	529	190,81	<0,001
9	BM	0,90	0,02	9	*	*	0,2	0	2	807	3,49	0,031	807	189,23	<0,001	535	193,61	<0,001
10	BM	0,90	0,02	10	*	*	0,2	0	2	807	5,96	0,003	807	211,57	<0,001	530	219,68	<0,001

Tab. D.22: Podsumowanie wyników testów *post-hoc* dla S w $\mathbb{S}_A$. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów $\mathbb{S}_A$ dla poniższych porównań przedstawiono w tab. D.21 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla β				Grupy jednorodne według β			
	3	5	10		Tukey (HSD)	Tamhane (T2)	Games-Howell (GH)	
1	1,26	0,60	1,47		[5] [3] [10]	[5] [3 10]	[5] [3 10]	
2	1,18	0,45	1,28		[5] [3 10]	[5] [3 10]	[5] [3 10]	
3	1,23	0,45	1,02		[5] [10] [3]	[5] [10] [3]	[5] [10] [3]	
4	1,24	0,47	0,86		[5] [10] [3]	[5] [10] [3]	[5] [10] [3]	
5	1,31	0,42	0,87		[5] [10] [3]	[5] [10] [3]	[5] [10] [3]	
6	1,28	0,44	0,78		[5] [10] [3]	[5] [10] [3]	[5] [10] [3]	
7	1,40	0,50	0,73		[5] [10] [3]	[5] [10] [3]	[5] [10] [3]	
8	1,36	0,51	0,74		[5] [10] [3]	[5] [10] [3]	[5] [10] [3]	
9	1,46	0,56	0,68		[5] [10] [3]	[5] [10] [3]	[5] [10] [3]	
10	1,45	0,55	0,69		[5] [10] [3]	[5] [10] [3]	[5] [10] [3]	

Tab. D.23: Podsumowanie wyników jednoczynnikowej analizy wariancji dla $p_m < 0,1$ w $\mathbb{S}_A$. Wielkość próby w każdej komórce wynosi $n = 270$.

#	β	Parametry $\mathbb{S}_A$						Test Levene'a			Test ANOVA			Test Welch'a			Test Browna-Forsythe'a				
		p_p	p_m	C	S	N	$\Delta_{\max}$	h	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_W	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	HM	0,10	★	5	10	30	0,2	0	5	1614	20,68	<0,001	1614	206,18	<0,001	751	133,47	<0,001	1379	206,18	<0,001
2	HM	0,30	★	5	10	30	0,2	0	5	1614	44,37	<0,001	1614	258,36	<0,001	750	124,50	<0,001	1128	258,36	<0,001
3	HM	0,50	★	5	10	30	0,2	0	5	1614	40,67	<0,001	1614	279,02	<0,001	750	134,27	<0,001	1153	279,02	<0,001
4	HM	0,70	★	5	10	30	0,2	0	5	1614	44,66	<0,001	1614	327,52	<0,001	749	138,96	<0,001	999	327,52	<0,001
5	HM	0,90	★	5	10	30	0,2	0	5	1614	56,07	<0,001	1614	366,57	<0,001	750	152,63	<0,001	987	366,57	<0,001
6	BM	0,10	★	5	10	30	0,2	0	5	1614	55,89	<0,001	1614	342,78	<0,001	748	199,22	<0,001	1047	342,78	<0,001
7	BM	0,30	★	5	10	30	0,2	0	5	1614	152,83	<0,001	1614	560,16	<0,001	747	198,94	<0,001	620	560,16	<0,001
8	BM	0,50	★	5	10	30	0,2	0	5	1614	152,96	<0,001	1614	696,70	<0,001	747	209,56	<0,001	538	696,70	<0,001
9	BM	0,70	★	5	10	30	0,2	0	5	1614	193,80	<0,001	1614	762,54	<0,001	747	205,77	<0,001	466	762,54	<0,001
10	BM	0,90	★	5	10	30	0,2	0	5	1614	223,14	<0,001	1614	739,79	<0,001	748	197,05	<0,001	467	739,79	<0,001

Tab. D.24: Podsumowanie wyników testów *post-hoc* dla $p_m < 0,1$ w $\mathbb{S}_A$. W oznaczeniach grup jednorodnych pominięto 0 na pierwszym miejscu przed przecinkiem. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów $\mathbb{S}_A$ dla poniższych porównań przedstawiono w tab. D.23 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla $p_m =$						Grupy jednorodne według β															
	0,00	0,01	0,02	0,04	0,06	0,08	Tukey (HSD)				Tamhane (T2)				Games-Howell (GH)							
1	12,40	5,31	5,50	6,07	6,87	7,65	[,01 ,02]	,04]	[,06]	[,08]	[,00]	[,01 ,02]	,04]	[,06]	[,08]	[,00]	[,01 ,02]	,04]	[,06]	[,08]	[,00]	
2	11,35	3,89	3,97	4,09	4,60	5,06	[,01 ,02]	,04]	[,06]	[,08]	[,00]	[,01 ,02]	,04]	[,06]	[,08]	[,00]	[,01 ,02]	,04]	[,06]	[,08]	[,00]	
3	11,02	3,52	3,42	3,48	4,00	4,20	[,02 ,04]	[,01 ,06]	[,08]	[,00]	[,02 ,04 ,01]	[,06]	[,08]	[,00]	[,02 ,04 ,01]	[,06]	[,08]	[,00]	[,02 ,04 ,01]	[,06]	[,08]	[,00]
4	11,09	3,40	3,21	3,26	3,20	3,81	[,06 ,02 ,04]	[,01 ,08]	[,00]	[,06 ,02 ,04 ,01]	[,08]	[,00]	[,06 ,02 ,04 ,01]	[,08]	[,00]	[,06 ,02 ,04 ,01]	[,08]	[,00]	[,06 ,02 ,04 ,01]	[,08]	[,00]	[,00]
5	10,82	3,07	2,92	2,98	3,01	3,41	[,02 ,04 ,06]	[,01 ,08]	[,00]	[,02 ,04 ,06 ,01]	[,08]	[,00]	[,02 ,04 ,06 ,01]	[,08]	[,00]	[,02 ,04 ,06 ,01]	[,08]	[,00]	[,02 ,04 ,06 ,01]	[,08]	[,00]	[,00]
6	8,42	2,25	2,52	3,15	3,68	4,38	[,01 ,02]	[,04]	[,06]	[,08]	[,00]	[,01 ,02]	[,04]	[,06]	[,08]	[,00]	[,01 ,02]	[,04]	[,06]	[,08]	[,00]	[,00]
7	7,39	1,21	1,26	1,47	1,70	2,25	[,01 ,02 ,04]	[,06]	[,08]	[,00]	[,01 ,02 ,04 ,06]	[,08]	[,00]	[,01 ,02 ,04 ,06]	[,08]	[,00]	[,01 ,02 ,04 ,06]	[,08]	[,00]	[,01 ,02 ,04 ,06]	[,08]	[,00]
8	7,39	0,99	0,95	1,13	1,26	1,56	[,02 ,01 ,04]	[,06]	[,08]	[,00]	[,02 ,01 ,04 ,06]	[,08]	[,00]	[,02 ,01 ,04 ,06]	[,08]	[,00]	[,02 ,01 ,04 ,06]	[,08]	[,00]	[,02 ,01 ,04 ,06]	[,08]	[,00]
9	7,42	0,91	0,84	0,97	1,08	1,18	[,02 ,01 ,04]	[,06]	[,08]	[,00]	[,02 ,01 ,04 ,06]	[,08]	[,00]	[,02 ,01 ,04 ,06]	[,08]	[,00]	[,02 ,01 ,04 ,06]	[,08]	[,00]	[,02 ,01 ,04 ,06]	[,08]	[,00]
10	7,20	0,87	0,87	0,87	0,92	1,11	[,02 ,01 ,04]	[,06]	[,08]	[,00]	[,02 ,01 ,04 ,06]	[,08]	[,00]	[,02 ,01 ,04 ,06]	[,08]	[,00]	[,02 ,01 ,04 ,06]	[,08]	[,00]	[,02 ,01 ,04 ,06]	[,08]	[,00]

Tab. D.25: Podsumowanie wyników jednoczynnikowej analizy wariancji dla $p_m \geq 0,1$ w $\mathbb{S}_A$. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry $\mathbb{S}_A$							Test Levene'a			Test ANOVA			Test Welch'a			Test Browna-Forsythe'a				
	β	p_p	p_m	C	S	N	$\Delta_{\max}$	h	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_W	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	HMI	0,10	★	5	10	30	0,2	0	4	1345	35,20	<0,001	1345	457,54	<0,001	660	551,90	<0,001	1047	457,54	<0,001
2	HMI	0,30	★	5	10	30	0,2	0	4	1345	58,92	<0,001	1345	546,84	<0,001	644	817,82	<0,001	952	546,84	<0,001
3	HMI	0,50	★	5	10	30	0,2	0	4	1345	64,43	<0,001	1345	644,17	<0,001	645	954,42	<0,001	929	644,17	<0,001
4	HMI	0,70	★	5	10	30	0,2	0	4	1345	69,79	<0,001	1345	628,54	<0,001	643	929,81	<0,001	942	628,54	<0,001
5	HMI	0,90	★	5	10	30	0,2	0	4	1345	75,35	<0,001	1345	669,36	<0,001	635	1050,89	<0,001	912	669,36	<0,001
6	BM	0,10	★	5	10	30	0,2	0	4	1345	71,01	<0,001	1345	626,74	<0,001	628	1098,62	<0,001	954	626,74	<0,001
7	BM	0,30	★	5	10	30	0,2	0	4	1345	96,74	<0,001	1345	740,69	<0,001	595	1493,27	<0,001	885	740,69	<0,001
8	BM	0,50	★	5	10	30	0,2	0	4	1345	98,48	<0,001	1345	769,58	<0,001	590	1453,30	<0,001	903	769,58	<0,001
9	BM	0,70	★	5	10	30	0,2	0	4	1345	116,76	<0,001	1345	745,64	<0,001	583	1451,68	<0,001	884	745,64	<0,001
10	BM	0,90	★	5	10	30	0,2	0	4	1345	144,41	<0,001	1345	766,41	<0,001	578	1443,49	<0,001	823	766,41	<0,001

Tab. D.26: Podsumowanie wyników testów *post-hoc* dla $p_m \geq 0,1$ w $\mathbb{S}_A$. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów $\mathbb{S}_A$ dla poniższych porównań przedstawiono w tab. D.25 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla $p_m =$						Grupy jednorodne według p_m											
	0,10	0,30	0,50	0,70	0,90		Tukey (HSD)				Tamhane (T2)				Games-Howell (GH)			
1	8,52	14,14	17,60	22,35	25,47		[0,10]	[0,30]	[0,50]	[0,70]	[0,90]	[0,10]	[0,30]	[0,50]	[0,70]	[0,90]	[0,90]	[0,90]
2	5,69	12,42	16,92	21,80	25,58		[0,10]	[0,30]	[0,50]	[0,70]	[0,90]	[0,10]	[0,30]	[0,50]	[0,70]	[0,70]	[0,90]	[0,90]
3	4,84	11,51	16,53	22,05	25,48		[0,10]	[0,30]	[0,50]	[0,70]	[0,90]	[0,10]	[0,30]	[0,50]	[0,70]	[0,70]	[0,90]	[0,90]
4	4,28	10,79	16,15	21,45	25,33		[0,10]	[0,30]	[0,50]	[0,70]	[0,90]	[0,10]	[0,30]	[0,50]	[0,70]	[0,70]	[0,90]	[0,90]
5	3,74	10,25	15,99	21,04	24,87		[0,10]	[0,30]	[0,50]	[0,70]	[0,90]	[0,10]	[0,30]	[0,50]	[0,70]	[0,70]	[0,90]	[0,90]
6	4,99	12,16	16,88	22,09	24,86		[0,10]	[0,30]	[0,50]	[0,70]	[0,90]	[0,10]	[0,30]	[0,50]	[0,70]	[0,70]	[0,90]	[0,90]
7	2,68	9,77	15,86	21,39	25,05		[0,10]	[0,30]	[0,50]	[0,70]	[0,90]	[0,10]	[0,30]	[0,50]	[0,70]	[0,70]	[0,90]	[0,90]
8	1,90	8,32	14,86	21,33	24,55		[0,10]	[0,30]	[0,50]	[0,70]	[0,90]	[0,10]	[0,30]	[0,50]	[0,70]	[0,70]	[0,90]	[0,90]
9	1,56	7,52	14,51	20,48	24,01		[0,10]	[0,30]	[0,50]	[0,70]	[0,90]	[0,10]	[0,30]	[0,50]	[0,70]	[0,70]	[0,90]	[0,90]
10	1,28	6,84	13,74	20,29	24,60		[0,10]	[0,30]	[0,50]	[0,70]	[0,90]	[0,10]	[0,30]	[0,50]	[0,70]	[0,70]	[0,90]	[0,90]

Tab. D.27: Podsumowanie wyników jednoczynnikowej analizy wariancji dla p_p w $\mathbb{S}_A$. Wielkość próby w każdej komórce wynosi $n = 270$.

#	β	p_p	p_m	C	S	N	Parametry $\mathbb{S}_A$			Test Levene'a			Test ANOVA			Test Welch'a			Test Brown-Forsythe'a		
							$\Delta_{\max}$	h	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_w	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	HMI	★	0,02	5	10	30	0,2	0	4	1345	2,38	0,050	1345	51,72	<0,001	672	49,41	<0,001	1321	51,72	<0,001
2	HMI	★	0,10	5	10	30	0,2	0	4	1345	8,97	<0,001	1345	142,05	<0,001	670	115,11	<0,001	1250	142,05	<0,001
3	HMI	★	0,30	5	10	30	0,2	0	4	1345	1,11	0,348	1345	46,06	<0,001	672	45,12	<0,001	1339	46,06	<0,001
4	HMI	★	0,50	5	10	30	0,2	0	4	1345	0,32	0,867	1345	4,98	<0,001	672	5,14	<0,001	1341	4,98	<0,001
5	BM	★	0,02	5	10	30	0,2	0	4	1345	28,14	<0,001	1345	131,77	<0,001	667	86,60	<0,001	1100	131,77	<0,001
6	BM	★	0,10	5	10	30	0,2	0	4	1345	44,19	<0,001	1345	305,77	<0,001	666	209,33	<0,001	1031	305,77	<0,001
7	BM	★	0,30	5	10	30	0,2	0	4	1345	9,34	<0,001	1345	100,89	<0,001	670	90,97	<0,001	1272	100,89	<0,001
8	BM	★	0,50	5	10	30	0,2	0	4	1345	4,50	0,001	1345	14,50	<0,001	671	16,37	<0,001	1305	14,50	<0,001

Tab. D.28: Podsumowanie wyników testów *post-hoc* dla p_p w $\mathbb{S}_A$. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów $\mathbb{S}_A$ dla poniższych porównań przedstawiono w tab. D.27 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla $p_p =$					Grupy jednorodne według p_p				
	0,10	0,30	0,50	0,70	0,90	Tukey (HSD)	Tamhane (T2)	Games-Howell (GH)		
1	5,50	3,97	3,42	3,21	2,92	[0,90 0,70 0,50 0,30] [0,10]	[0,90 0,70 0,50 0,30] [0,10]	[0,90 0,70 0,50 0,30] [0,10]	[0,90 0,70 0,50 0,30] [0,10]	[0,10]
2	8,52	5,69	4,84	4,28	3,74	[0,90 0,70 0,50] [0,30] [0,10]	[0,90 0,70 0,50] [0,30] [0,10]	[0,90 0,70 0,50] [0,30] [0,10]	[0,90 0,70 0,50] [0,30] [0,10]	[0,10]
3	14,14	12,42	11,51	10,79	10,25	[0,90 0,70 0,50] [0,30] [0,10]	[0,90 0,70 0,50] [0,30] [0,10]	[0,90 0,70 0,50] [0,30] [0,10]	[0,90 0,70 0,50] [0,30] [0,10]	[0,10]
4	17,60	16,92	16,53	16,15	15,99	[0,90 0,70 0,50 0,30] 0,10]	[0,90 0,70 0,50 0,30] 0,10]	[0,90 0,70 0,50 0,30] 0,10]	[0,90 0,70 0,50 0,30] 0,10]	[0,10]
5	2,52	1,26	0,95	0,84	0,87	[0,70 0,90 0,50] [0,30] [0,10]	[0,70 0,90 0,50] [0,30] [0,10]	[0,70 0,90 0,50] [0,30] [0,10]	[0,70 0,90 0,50] [0,30] [0,10]	[0,10]
6	4,99	2,68	1,90	1,56	1,28	[0,90 0,70] [0,50] [0,30] [0,10]	[0,90] [0,70] [0,50] [0,30] [0,10]	[0,90] [0,70] [0,50] [0,30] [0,10]	[0,90] [0,70] [0,50] [0,30] [0,10]	[0,10]
7	12,16	9,77	8,32	7,52	6,84	[0,90 0,70 0,50] [0,30] [0,10]	[0,90 0,70] [0,50] [0,30] [0,10]	[0,90 0,70] [0,50] [0,30] [0,10]	[0,90 0,70] [0,50] [0,30] [0,10]	[0,10]
8	16,88	15,86	14,86	14,51	13,74	[0,90 0,70 0,50] [0,30] 0,10]	[0,90 0,70 0,50] [0,30] 0,10]	[0,90 0,70 0,50] [0,30] 0,10]	[0,90 0,70 0,50] [0,30] 0,10]	[0,10]

Tab. D.29: Podsumowanie wyników jednoczynnikowej analizy wariancji dla $\Delta_{\max}$ w $\mathbb{S}\mathbb{A}$. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry SA								df1	Test Levene'a			Test ANOVA		Test Welch'a		Test Browna-Forsythe'a				
	β	p_p	p_m	C	S	N	$\Delta_{\max}$	h		df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_W	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	BM	0,90	0,02	1	5	1973	*	0	2	807	0,75	0,471	807	0,10	0,909	512	0,16	0,854	569	0,10	0,909
2	BM	0,90	0,02	2	5	989	*	0	2	807	2,52	0,081	807	1,15	0,319	536	1,16	0,314	796	1,15	0,319
3	BM	0,90	0,02	3	5	659	*	0	2	807	1,28	0,278	807	0,06	0,938	533	0,06	0,944	778	0,06	0,938
4	BM	0,90	0,02	4	5	494	*	0	2	807	4,44	0,012	807	1,18	0,307	534	1,05	0,352	777	1,18	0,307
5	BM	0,90	0,02	5	5	396	*	0	2	807	3,21	0,041	807	4,17	0,016	530	3,93	0,020	773	4,17	0,016
6	BM	0,90	0,02	6	5	330	*	0	2	807	1,51	0,222	807	0,73	0,483	512	1,00	0,367	635	0,73	0,483
7	BM	0,90	0,02	7	5	283	*	0	2	807	2,88	0,057	807	3,94	0,020	536	4,01	0,019	797	3,94	0,020
8	BM	0,90	0,02	8	5	248	*	0	2	807	1,85	0,158	807	0,38	0,686	536	0,41	0,665	796	0,38	0,686
9	BM	0,90	0,02	9	5	220	*	0	2	807	5,59	0,004	807	0,57	0,565	532	0,59	0,553	778	0,57	0,565
10	BM	0,90	0,02	10	5	199	*	0	2	807	0,02	0,982	807	0,16	0,849	538	0,16	0,850	805	0,16	0,849

Tab. D.30: Podsumowanie wyników testów *post-hoc* dla $\Delta_{\max}$ w $\mathbb{S}\mathbb{A}$. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów $\mathbb{S}\mathbb{A}$ dla poniższych porównań przedstawiono w tab. D.29 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla $\Delta_{\max} =$			Grupy jednorodne według $\Delta_{\max}$			
	0,10	0,20	0,50	Tukey (HSD)			Games-Howell (GH)
1	0,64	0,60	0,64	[0,20 0,50 0,10]			[0,20 0,50 0,10]
2	0,53	0,45	0,49	[0,20 0,50 0,10]			[0,20 0,50 0,10]
3	0,46	0,45	0,46	[0,20 0,50 0,10]			[0,20 0,50 0,10]
4	0,41	0,47	0,42	[0,10 0,50 0,20]			[0,10 0,50 0,20]
5	0,54	0,42	0,43	[0,20 0,50] [0,10]			[0,20 0,50 0,10]
6	0,49	0,44	0,50	[0,20 0,10 0,50]			[0,20 0,10 0,50]
7	0,55	0,50	0,43	[0,50 0,20 0,10]			[0,50 0,20 0,10]
8	0,55	0,51	0,55	[0,20 0,50 0,10]			[0,20 0,50 0,10]
9	0,58	0,56	0,53	[0,50 0,20 0,10]			[0,50 0,20 0,10]
10	0,56	0,55	0,57	[0,20 0,10 0,50]			[0,20 0,10 0,50]

Tab. D.31: Podsumowanie wyników jednoczynnikowej analizy wariancji dla β w TŚ. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry TŚ				Test Levene'a			Test ANOVA			Test Welch'a			Test Browna-Forsythe'a		
	β	$S_{\max}$	M_m	M_p	$T_{\max}$	df1	df2	L	$p(H_0)$	F	df2	F_w	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	★	25	10	10	3	2	807	38,02	<0,001	807	81,25	<0,001	<0,001	521	60,99	<0,001
2	★	25	10	10	6	2	807	30,95	<0,001	807	66,60	<0,001	<0,001	522	50,07	<0,001
3	★	25	10	10	9	2	807	23,59	<0,001	807	74,26	<0,001	<0,001	522	56,23	<0,001
4	★	50	10	10	3	2	807	47,63	<0,001	807	109,59	<0,001	<0,001	520	81,45	<0,001
5	★	50	10	10	6	2	807	30,84	<0,001	807	102,91	<0,001	<0,001	523	79,46	<0,001
6	★	50	10	10	9	2	807	45,67	<0,001	807	92,13	<0,001	<0,001	519	67,80	<0,001
7	★	100	10	10	3	2	807	23,66	<0,001	807	113,33	<0,001	<0,001	524	88,49	<0,001
8	★	100	10	10	6	2	807	27,81	<0,001	807	120,74	<0,001	<0,001	523	93,16	<0,001
9	★	100	10	10	9	2	807	42,94	<0,001	807	135,70	<0,001	<0,001	515	95,23	<0,001

Tab. D.32: Podsumowanie wyników testów *post-hoc* dla β w TŚ. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów TŚ dla poniższych porównań przedstawiono w tab. D.31 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}$ [%] dla β			Grupy jednorodne według β					
	HM	BM	MM	Tukey (HSD)		Tamhane (T2)		Games-Howell (GH)	
1	8,92	6,10	5,77	[MM BM]	[HM]	[MM BM]	[HM]	[MM BM]	[HM]
2	8,43	5,86	5,67	[MM BM]	[HM]	[MM BM]	[HM]	[MM BM]	[HM]
3	8,48	5,74	5,74	[BM MM]	[HM]	[BM MM]	[HM]	[BM MM]	[HM]
4	9,34	6,18	5,70	[MM BM]	[HM]	[MM BM]	[HM]	[MM BM]	[HM]
5	9,26	6,24	5,73	[MM BM]	[HM]	[MM BM]	[HM]	[MM BM]	[HM]
6	9,37	6,25	5,85	[MM BM]	[HM]	[MM BM]	[HM]	[MM BM]	[HM]
7	10,07	6,25	6,36	[BM MM]	[HM]	[BM MM]	[HM]	[BM MM]	[HM]
8	10,15	6,35	6,21	[MM BM]	[HM]	[MM BM]	[HM]	[MM BM]	[HM]
9	10,55	6,34	6,15	[MM BM]	[HM]	[MM BM]	[HM]	[MM BM]	[HM]

Tab. D.33: Podsumowanie wyników jednoczynnikowej analizy wariancji dla $S_{\max}$ w TS. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry TS					Test Levene'a			Test ANOVA			Test Welch'a			Test Browna-Forsythe'a			
	β	$S_{\max}$	M_m	M_p	$T_{\max}$	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_W	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	HM	★	10	10	3	2	807	0,01	0,990	807	5,34	0,005	538	5,24	0,006	806	5,34	0,005
2	HM	★	10	10	6	2	807	0,77	0,462	807	12,21	<0,001	538	11,86	<0,001	804	12,21	<0,001
3	HM	★	10	10	9	2	807	5,00	0,007	807	15,49	<0,001	534	15,40	<0,001	784	15,49	<0,001
4	BM	★	10	10	3	2	807	0,70	0,498	807	0,22	0,806	537	0,21	0,812	801	0,22	0,806
5	BM	★	10	10	6	2	807	1,64	0,194	807	2,72	0,067	538	2,75	0,065	804	2,72	0,067
6	BM	★	10	10	9	2	807	1,14	0,320	807	4,51	0,011	538	4,67	0,010	804	4,51	0,011
7	MM	★	10	10	3	2	807	3,19	0,042	807	4,79	0,009	536	4,39	0,013	792	4,79	0,009
8	MM	★	10	10	6	2	807	2,92	0,054	807	3,30	0,038	536	3,05	0,048	796	3,30	0,038
9	MM	★	10	10	9	2	807	0,77	0,463	807	1,70	0,183	537	1,69	0,185	804	1,70	0,183

Tab. D.34: Podsumowanie wyników testów *post-hoc* dla $S_{\max}$ w TS. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów TS dla poniższych porównań przedstawiono w tab. D.33 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}$ [%] dla $S_{\max} =$			Grupy jednorodne według $S_{\max}$		
	25	50	100	Tukey (HSD)	Tamhane (T2)	Games-Howell (GH)
1	8,92	9,34	10,07	[25 50 100]	[25 50 100]	[25 50 100]
2	8,43	9,26	10,15	[25] [50] [100]	[25] [50] [100]	[25] [50] [100]
3	8,48	9,37	10,55	[25] [50] [100]	[25] [50] [100]	[25] [50] [100]
4	6,10	6,18	6,25	[25 50 100]	[25 50 100]	[25 50 100]
5	5,86	6,24	6,35	[25 50 100]	[25 50 100]	[25 50 100]
6	5,74	6,25	6,34	[25] [50 100]	[25] [50 100]	[25] [50 100]
7	5,77	5,70	6,36	[50 25] [100]	[50 25] [100]	[50 25] [100]
8	5,67	5,73	6,21	[25 50 100]	[25 50 100]	[25 50 100]
9	5,74	5,85	6,15	[25 50 100]	[25 50 100]	[25 50 100]

Tab. D.35: Podsumowanie wyników jednoczynnikowej analizy wariancji dla M_m w TS. Wielkość próby w każdej komórce wynosi $n = 270$.

#	β	$S_{\max}$	Parametry TS			df1	Test Levene'a			Test ANOVA			Test Welch'a			Test Browna-Forsythe'a		
			M_m	M_p	$T_{\max}$		df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_w	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	HM	10	★	10	5	2	807	0,57	0,566	807	0,55	0,575	538	0,55	0,580	807	0,55	0,575
2	HM	20	★	10	5	2	807	0,13	0,878	807	0,23	0,793	538	0,23	0,797	806	0,23	0,793
3	HM	40	★	10	5	2	807	1,47	0,230	807	1,27	0,281	537	1,21	0,300	803	1,27	0,281
4	BM	10	★	10	5	2	807	0,37	0,689	807	0,16	0,852	538	0,17	0,848	805	0,16	0,852
5	BM	20	★	10	5	2	807	0,00	0,997	807	0,07	0,930	538	0,07	0,929	807	0,07	0,930
6	BM	40	★	10	5	2	807	2,44	0,088	807	1,39	0,249	537	1,48	0,230	801	1,39	0,249
7	MM	10	★	10	5	2	807	0,55	0,578	807	0,11	0,892	538	0,11	0,893	805	0,11	0,892
8	MM	20	★	10	5	2	807	0,45	0,637	807	0,03	0,967	538	0,03	0,968	805	0,03	0,967
9	MM	40	★	10	5	2	807	0,64	0,527	807	0,11	0,897	538	0,11	0,898	806	0,11	0,897
10	HM	20	★	50	5	2	807	3,69	0,025	807	0,41	0,666	534	0,37	0,689	787	0,41	0,666
11	HM	40	★	50	5	2	807	0,01	0,988	807	0,31	0,731	538	0,32	0,728	807	0,31	0,731
12	BM	20	★	50	5	2	807	0,22	0,806	807	0,07	0,937	538	0,06	0,938	806	0,07	0,937
13	BM	40	★	50	5	2	807	0,38	0,687	807	0,09	0,912	538	0,09	0,912	806	0,09	0,912
14	MM	20	★	50	5	2	807	0,46	0,633	807	0,80	0,452	538	0,78	0,458	806	0,80	0,452
15	MM	40	★	50	5	2	807	1,80	0,167	807	0,52	0,594	536	0,53	0,587	797	0,52	0,594

Tab. D.36: Podsumowanie wyników testów *post-hoc* dla M_m w $\mathbb{T}\mathbb{S}$. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów $\mathbb{T}\mathbb{S}$ dla poniższych porównań przedstawiono w tab. D.35 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla $M_m =$			Grupy jednorodne według M_m			
	10	50	100	Tukey (HSD)	Tamhane (T2)	Games-Howell (GH)	
1	7,88	8,22	8,04	[10 100 50]	[10 100 50]	[10 100 50]	
2	8,84	8,76	8,99	[50 10 100]	[50 10 100]	[50 10 100]	
3	10,37	9,78	10,04	[50 100 10]	[50 100 10]	[50 100 10]	
4	5,73	5,67	5,79	[50 10 100]	[50 10 100]	[50 10 100]	
5	5,97	5,92	5,88	[100 50 10]	[100 50 10]	[100 50 10]	
6	5,98	5,91	5,65	[100 50 10]	[100 50 10]	[100 50 10]	
7	5,32	5,25	5,23	[100 50 10]	[100 50 10]	[100 50 10]	
8	5,55	5,56	5,60	[10 50 100]	[10 50 100]	[10 50 100]	
9	5,80	5,85	5,91	[10 50 100]	[10 50 100]	[10 50 100]	
10	8,18	8,42	8,16	[100 10 50]	[100 10 50]	[100 10 50]	
11	8,96	9,10	8,83	[100 10 50]	[100 10 50]	[100 10 50]	
12	5,90	5,92	5,85	[100 10 50]	[100 10 50]	[100 10 50]	
13	5,83	5,83	5,75	[100 10 50]	[100 10 50]	[100 10 50]	
14	5,68	5,45	5,45	[50 100 10]	[50 100 10]	[50 100 10]	
15	5,66	5,88	5,79	[10 100 50]	[10 100 50]	[10 100 50]	

Tab. D.37: Podsumowanie wyników jednoczynnikowej analizy wariancji dla M_p w TS. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry TS					$\bar{\epsilon}[\%]$ dla M_p			Test Levene'a			Test ANOVA			Test Welch'a		
	β	$S_{\max}$	M_m	M_p	$T_{\max}$	10	50	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_w	$p(H_0)$
1	HMI	20	10	★	5	8,84	8,18	1	538	5,34	0,021	538	4,50	0,034	524	4,50	0,034
2	HMI	20	50	★	5	8,76	8,42	1	538	0,16	0,686	538	0,94	0,332	538	0,94	0,332
3	HMI	20	100	★	5	8,99	8,16	1	538	1,30	0,254	538	5,94	0,015	536	5,94	0,015
4	HMI	40	10	★	5	10,37	8,96	1	538	5,45	0,020	538	15,30	<0,001	530	15,30	<0,001
5	HMI	40	50	★	5	9,78	9,10	1	538	2,46	0,118	538	3,86	0,05	530	3,86	0,050
6	HMI	40	100	★	5	10,03	8,83	1	538	0,44	0,505	538	12,57	<0,001	537	12,57	<0,001
7	BMI	20	10	★	5	5,97	5,90	1	538	0,09	0,769	538	0,11	0,746	538	0,11	0,746
8	BMI	20	50	★	5	5,92	5,92	1	538	0,14	0,712	538	0,00	0,975	538	0,00	0,975
9	BMI	20	100	★	5	5,88	5,85	1	538	0,01	0,944	538	0,03	0,863	538	0,03	0,863
10	BMI	40	10	★	5	5,98	5,83	1	538	2,16	0,142	538	0,49	0,486	533	0,49	0,486
11	BMI	40	50	★	5	5,91	5,83	1	538	0,98	0,323	538	0,12	0,725	537	0,12	0,725
12	BMI	40	100	★	5	5,65	5,75	1	538	1,64	0,202	538	0,23	0,632	534	0,23	0,632
13	MIM	20	10	★	5	5,54	5,68	1	538	0,14	0,704	538	0,40	0,529	537	0,40	0,529
14	MIM	20	50	★	5	5,56	5,45	1	538	0,02	0,880	538	0,26	0,609	538	0,26	0,609
15	MIM	20	100	★	5	5,60	5,45	1	538	1,50	0,222	538	0,48	0,489	537	0,48	0,489
16	MIM	40	10	★	5	5,80	5,65	1	538	0,44	0,509	538	0,45	0,504	533	0,45	0,504
17	MIM	40	50	★	5	5,85	5,88	1	538	0,32	0,572	538	0,02	0,887	538	0,02	0,887
18	MIM	40	100	★	5	5,91	5,78	1	538	0,58	0,447	538	0,29	0,592	536	0,29	0,592

Tab. D.38: Podsumowanie wyników jednoczynnikowej analizy wariancji dla $T_{\max}$ w TS. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry TS					Test Levene'a			Test ANOVA			Test Welch'a			Test Browna-Forsythe'a			
	β	$S_{\max}$	M_m	M_p	$T_{\max}$	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_W	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	HM	25	10	10	★	2	807	1,27	0,283	807	1,26	0,285	538	1,22	0,296	805	1,26	0,285
2	BM	25	10	10	★	2	807	1,33	0,265	807	0,05	0,955	537	0,05	0,954	802	0,05	0,955
3	MM	25	10	10	★	2	807	1,37	0,255	807	0,92	0,400	536	0,85	0,429	795	0,92	0,400
4	HM	50	10	10	★	2	807	0,61	0,545	807	1,49	0,226	538	1,49	0,227	806	1,49	0,226
5	BM	50	10	10	★	2	807	0,03	0,973	807	0,06	0,940	538	0,06	0,938	806	0,06	0,940
6	MM	50	10	10	★	2	807	0,07	0,928	807	0,13	0,875	538	0,13	0,878	806	0,13	0,875
7	HM	100	10	10	★	2	807	0,06	0,945	807	0,11	0,895	538	0,11	0,896	807	0,11	0,895
8	BM	100	10	10	★	2	807	0,75	0,473	807	0,24	0,789	538	0,23	0,794	804	0,24	0,789
9	MM	100	10	10	★	2	807	0,79	0,456	807	0,37	0,693	537	0,37	0,692	803	0,37	0,693

Tab. D.39: Podsumowanie wyników testów *post-hoc* dla $T_{\max}$ w TS. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów TS dla poniższych porównań przedstawiono w tab. D.38 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla $T_{\max} =$			Grupy jednorodne według $T_{\max}$		
	3	6	9	Tukey (HSD)	Tamhane (T2)	Games-Howell (GH)
1	8,92	8,43	8,48	[6 9 3]	[6 9 3]	[6 9 3]
2	9,34	9,26	9,37	[6 3 9]	[6 3 9]	[6 3 9]
3	10,07	10,15	10,55	[3 6 9]	[3 6 9]	[3 6 9]
4	6,10	5,86	5,74	[9 6 3]	[9 6 3]	[9 6 3]
5	6,18	6,24	6,25	[3 6 9]	[3 6 9]	[3 6 9]
6	6,25	6,35	6,34	[3 9 6]	[3 9 6]	[3 9 6]
7	5,77	5,67	5,74	[6 9 3]	[6 9 3]	[6 9 3]
8	5,70	5,73	5,85	[3 6 9]	[3 6 9]	[3 6 9]
9	6,36	6,21	6,15	[9 6 3]	[9 6 3]	[9 6 3]

Tab. D.40: Podsumowanie wyników jednoczynnikowej analizy wariancji dla $\mathcal{P}$ i $g_{\max}$ w HIA. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry HIA										Test Levene'a			Test ANOVA			Test Welch'a			Test Browna-Forsythe'a		
	$\bar{GA}/\bar{\Lambda}$	$\hat{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_w	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	0,25	★	★	2PX	BM	1	3	3628	0,01	5	1614	5,64	<0,001	1614	2,20	0,052	751	1,79	0,113	1493	2,20	0,052
2	0,25	★	★	2PX	BM	1	5	1480	0,01	5	1614	4,70	<0,001	1614	2,75	0,018	751	2,82	0,016	1501	2,75	0,018
3	0,25	★	★	2PX	BM	1	10	106	0,01	5	1614	10,92	<0,001	1614	7,17	<0,001	751	7,30	<0,001	1481	7,17	<0,001
4	0,25	★	★	2PX	BM	2	3	1814	0,01	5	1614	3,72	0,002	1614	2,26	0,046	751	2,08	0,066	1512	2,26	0,046
5	0,25	★	★	2PX	BM	2	5	741	0,01	5	1614	9,16	<0,001	1614	4,16	<0,001	750	3,80	0,002	1452	4,16	<0,001
6	0,25	★	★	MIX	BM	1	3	3628	0,01	5	1614	2,86	0,014	1614	1,27	0,276	752	0,91	0,474	1483	1,27	0,276
7	0,25	★	★	MIX	BM	1	5	1480	0,01	5	1614	2,84	0,015	1614	2,01	0,075	752	1,76	0,120	1515	2,01	0,075
8	0,25	★	★	MIX	BM	1	10	106	0,01	5	1614	2,91	0,013	1614	3,10	0,009	752	3,27	0,006	1562	3,10	0,009
9	0,25	★	★	MIX	BM	2	3	1814	0,01	5	1614	3,80	0,002	1614	1,10	0,358	751	1,02	0,407	1492	1,10	0,358
10	0,25	★	★	MIX	BM	2	5	741	0,01	5	1614	1,44	0,208	1614	1,35	0,242	752	1,16	0,327	1531	1,35	0,242
11	0,50	★	★	2PX	BM	1	3	2419	0,01	5	1614	3,69	0,003	1614	2,98	0,011	751	2,40	0,036	1425	2,98	0,011
12	0,50	★	★	2PX	BM	1	5	988	0,01	5	1614	7,90	<0,001	1614	4,88	<0,001	750	4,11	0,001	1386	4,88	<0,001
13	0,50	★	★	2PX	BM	1	10	71	0,01	5	1614	10,46	<0,001	1614	8,19	<0,001	750	6,46	<0,001	1349	8,19	<0,001
14	0,50	★	★	2PX	BM	2	3	1210	0,01	5	1614	6,90	<0,001	1614	2,91	0,013	749	2,41	0,035	1385	2,91	0,013
15	0,50	★	★	2PX	BM	2	5	494	0,01	5	1614	9,02	<0,001	1614	4,68	<0,001	750	3,59	0,003	1339	4,68	<0,001
16	0,50	★	★	MIX	BM	1	3	2419	0,01	5	1614	1,77	0,115	1614	0,81	0,546	753	0,78	0,562	1582	0,81	0,546
17	0,50	★	★	MIX	BM	1	5	988	0,01	5	1614	1,84	0,103	1614	0,94	0,451	753	0,95	0,447	1589	0,94	0,451
18	0,50	★	★	MIX	BM	1	10	71	0,01	5	1614	1,89	0,094	1614	3,50	0,004	753	3,19	0,007	1587	3,50	0,004
19	0,50	★	★	MIX	BM	2	3	1210	0,01	5	1614	1,13	0,343	1614	0,54	0,743	753	0,49	0,783	1593	0,54	0,743
20	0,50	★	★	MIX	BM	2	5	494	0,01	5	1614	0,78	0,565	1614	0,55	0,742	753	0,59	0,707	1595	0,55	0,742
21	0,75	★	★	2PX	BM	1	3	1210	0,01	5	1614	11,22	<0,001	1614	3,98	0,001	751	2,62	0,023	1404	3,98	0,001
22	0,75	★	★	2PX	BM	1	5	494	0,01	5	1614	10,32	<0,001	1614	9,32	<0,001	751	6,28	<0,001	1407	9,32	<0,001
23	0,75	★	★	2PX	BM	1	10	37	0,01	5	1614	13,80	<0,001	1614	14,58	<0,001	750	10,26	<0,001	1356	14,58	<0,001
24	0,75	★	★	2PX	BM	2	3	605	0,01	5	1614	6,97	<0,001	1614	4,29	<0,001	751	3,12	0,009	1430	4,29	<0,001
25	0,75	★	★	2PX	BM	2	5	248	0,01	5	1614	10,63	<0,001	1614	7,46	<0,001	750	5,59	<0,001	1403	7,46	<0,001
26	0,75	★	★	MIX	BM	1	3	1210	0,01	5	1614	2,79	0,016	1614	1,84	0,102	752	1,85	0,101	1556	1,84	0,102
27	0,75	★	★	MIX	BM	1	5	494	0,01	5	1614	3,44	0,004	1614	4,25	<0,001	752	3,66	0,003	1535	4,25	<0,001
28	0,75	★	★	MIX	BM	1	10	37	0,01	5	1614	8,25	<0,001	1614	9,94	<0,001	752	8,61	<0,001	1523	9,94	<0,001
29	0,75	★	★	MIX	BM	2	3	605	0,01	5	1614	2,26	0,046	1614	1,85	0,099	752	1,74	0,123	1575	1,85	0,099
30	0,75	★	★	MIX	BM	2	5	248	0,01	5	1614	6,59	<0,001	1614	4,66	<0,001	752	3,83	0,002	1512	4,66	<0,001

Tab. D.41: Podsumowanie wyników testów *post-hoc* dla $\hat{\mathcal{P}}$ i $g_{\max}$ w $\mathbb{H}_A$. W zestawieniu przedstawiono jedynie wartość $\hat{\mathcal{P}}$, ponieważ wartość $g_{\max}$ zależy od $\hat{\mathcal{P}}$. Wyniki analizy wariancji wraz ze statystykami wartościami parametrów $\mathbb{H}_A$ dla poniższych porównań przedstawiono w tab. D.40 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla $\hat{\mathcal{P}} =$					Grupy jednorodne według $\hat{\mathcal{P}}$			
	25	50	100	200	250	500	Tukey (HSD)	Tamhane (T2)	Games-Howell (GH)
1	0,55	0,44	0,42	0,39	0,41	0,45	[200 250 100 50 500 25]	[200 250 100 50 500 25]	[200 250 100 50 500 25]
2	0,68	0,62	0,56	0,50	0,53	0,61	[200 250 100 500 50 25]	[200 250 100 500 50 25]	[200 250 100 500 50 25]
3	1,05	0,86	0,71	0,70	0,83	0,97	[200 100 250 50 500 25]	[200 100 250 50 500 25]	[200 100 250 50 500 25]
4	0,49	0,42	0,39	0,34	0,36	0,39	[200 250 100 500 50 25]	[200 250 100 500 50 25]	[200 250 100 500 50 25]
5	0,69	0,59	0,48	0,46	0,51	0,59	[200 100 250 500 50 25]	[200 100 250 500 50 25]	[200 100 250 500 50 25]
6	0,54	0,45	0,43	0,45	0,42	0,45	[250 100 500 200 50 25]	[250 100 500 200 50 25]	[250 100 500 200 50 25]
7	0,74	0,61	0,63	0,56	0,58	0,66	[200 250 50 100 500 25]	[200 250 50 100 500 25]	[200 250 50 100 500 25]
8	1,03	0,91	0,86	0,81	0,93	1,07	[200 100 50 250 25 500]	[200 100 50 250 25 500]	[200 100 50 250 25 500]
9	0,49	0,44	0,41	0,39	0,41	0,37	[500 200 100 250 50 25]	[500 200 100 250 50 25]	[500 200 100 250 50 25]
10	0,66	0,59	0,56	0,53	0,52	0,59	[250 200 100 500 50 25]	[250 200 100 500 50 25]	[250 200 100 500 50 25]
11	0,54	0,45	0,46	0,38	0,38	0,40	[250 200 500 50 100 25]	[250 200 500 50 100 25]	[250 200 500 50 100 25]
12	0,73	0,64	0,58	0,48	0,53	0,54	[200 250 500 100 50 25]	[200 250 500 100 50 25]	[200 250 500 100 50 25]
13	0,96	0,78	0,68	0,61	0,60	0,75	[250 200 100 500 50 25]	[250 200 100 500 50 25]	[250 200 100 500 50 25]
14	0,52	0,46	0,43	0,37	0,36	0,39	[250 200 500 100 50 25]	[250 200 500 100 50 25]	[250 200 500 100 50 25]
15	0,67	0,59	0,51	0,45	0,46	0,49	[200 250 500 100 50 25]	[200 250 500 100 50 25]	[200 250 500 100 50 25]
16	0,51	0,55	0,46	0,47	0,47	0,51	[100 200 250 25 500 50]	[100 200 250 25 500 50]	[100 200 250 25 500 50]
17	0,70	0,64	0,62	0,64	0,58	0,68	[250 100 200 50 500 25]	[250 100 200 50 500 25]	[250 100 200 50 500 25]
18	0,99	0,83	0,77	0,74	0,76	0,89	[200 250 100 50 500 25]	[200 250 100 50 500 25]	[200 250 100 50 500 25]
19	0,53	0,47	0,46	0,45	0,49	0,48	[200 100 50 500 250 25]	[200 100 50 500 250 25]	[200 100 50 500 250 25]
20	0,62	0,62	0,57	0,60	0,55	0,62	[250 100 200 500 50 25]	[250 100 200 500 50 25]	[250 100 200 500 50 25]
21	0,68	0,51	0,54	0,49	0,49	0,48	[500 200 250 50 100 25]	[500 200 250 50 100 25]	[500 200 250 50 100 25]
22	0,87	0,61	0,61	0,52	0,59	0,58	[200 500 250 50 100 25]	[200 500 250 50 100 25]	[200 500 250 50 100 25]
23	1,02	0,78	0,67	0,57	0,59	0,62	[200 250 500 100 50 25]	[200 250 500 100 50 25]	[200 250 500 100 50 25]
24	0,67	0,53	0,53	0,46	0,50	0,47	[200 500 250 100 50 25]	[200 500 250 100 50 25]	[200 500 250 100 50 25]
25	0,77	0,61	0,56	0,51	0,50	0,48	[500 250 200 100 50 25]	[500 250 200 100 50 25]	[500 250 200 100 50 25]
26	0,67	0,62	0,60	0,53	0,52	0,58	[250 200 500 100 50 25]	[250 200 500 100 50 25]	[250 200 500 100 50 25]
27	0,89	0,73	0,71	0,67	0,63	0,69	[250 200 500 100 50 25]	[250 200 500 100 50 25]	[250 200 500 100 50 25]
28	1,07	0,88	0,73	0,71	0,67	0,80	[250 200 100 500 50 25]	[250 200 100 500 50 25]	[250 200 100 500 50 25]
29	0,70	0,61	0,58	0,57	0,56	0,63	[250 200 100 50 500 25]	[250 200 100 50 500 25]	[250 200 100 50 500 25]
30	0,86	0,72	0,65	0,61	0,61	0,67	[200 250 100 500 50 25]	[200 250 100 500 50 25]	[200 250 100 500 50 25]

Tab. D.42: Podsumowanie wyników jednoczynnikowej analizy wariancji dla $\tilde{G}\tilde{A}$ i $\tilde{S}\tilde{A}$ w $\mathbb{H}\tilde{A}$. W zestawieniu przedstawiono jedynie $\tilde{G}\tilde{A}$, wartości pozostałych zmiennych parametrów $g_{\max}$, $\tilde{S}\tilde{A}$, N wynikają z ograniczenia liczby budowanych rozwiązań ($\tilde{\Lambda} = 20\,000$). Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry H _A										Test Levene'a			Test ANOVA			Test Welch'a			Test Brown-Forsythe'a		
	$\tilde{G}_A/\tilde{\Lambda}$	$\tilde{\mathcal{P}}$	$g_{\max}$	α_{G_A}	β_{S_A}	C	S	N	$\Delta_{\max}$	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_W	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	★	25	★	2PX	BM	1	3	★	0,01	2	807	2,02	0,134	807	2,36	0,096	538	2,29	0,102	806	2,36	0,096
2	★	25	★	2PX	BM	1	5	★	0,01	2	807	0,91	0,403	807	3,62	0,027	536	3,65	0,027	798	3,62	0,027
3	★	25	★	2PX	BM	1	10	★	0,01	2	807	1,06	0,348	807	0,44	0,646	538	0,42	0,657	804	0,44	0,646
4	★	25	★	2PX	BM	2	3	★	0,01	2	807	1,26	0,284	807	4,39	0,013	535	4,29	0,014	794	4,39	0,013
5	★	25	★	2PX	BM	2	5	★	0,01	2	807	0,15	0,865	807	0,92	0,400	537	0,92	0,399	804	0,92	0,400
6	★	25	★	MIX	BM	1	3	★	0,01	2	807	0,55	0,577	807	3,16	0,043	535	3,42	0,033	788	3,16	0,043
7	★	25	★	MIX	BM	1	5	★	0,01	2	807	0,55	0,578	807	3,85	0,022	535	4,16	0,016	788	3,85	0,022
8	★	25	★	MIX	BM	1	10	★	0,01	2	807	1,03	0,357	807	0,47	0,623	535	0,53	0,591	789	0,47	0,624
9	★	25	★	MIX	BM	2	3	★	0,01	2	807	0,42	0,657	807	6,73	0,001	536	6,73	0,001	796	6,73	0,001
10	★	25	★	MIX	BM	2	5	★	0,01	2	807	4,22	0,015	807	6,42	0,002	532	6,35	0,002	781	6,42	0,002
11	★	50	★	2PX	BM	1	3	★	0,01	2	807	1,65	0,193	807	1,05	0,352	535	1,10	0,333	787	1,05	0,352
12	★	50	★	2PX	BM	1	5	★	0,01	2	807	0,89	0,412	807	0,10	0,906	534	0,11	0,896	784	0,10	0,906
13	★	50	★	2PX	BM	1	10	★	0,01	2	807	2,05	0,130	807	0,95	0,386	534	0,83	0,436	774	0,95	0,386
14	★	50	★	2PX	BM	2	3	★	0,01	2	807	0,17	0,843	807	2,12	0,121	536	2,23	0,108	797	2,12	0,121
15	★	50	★	2PX	BM	2	5	★	0,01	2	807	0,68	0,508	807	0,07	0,933	534	0,08	0,923	782	0,07	0,933
16	★	50	★	MIX	BM	1	3	★	0,01	2	807	0,73	0,482	807	3,94	0,020	536	3,86	0,022	796	3,94	0,020
17	★	50	★	MIX	BM	1	5	★	0,01	2	807	0,43	0,652	807	1,73	0,178	537	1,63	0,197	799	1,73	0,178
18	★	50	★	MIX	BM	1	10	★	0,01	2	807	1,34	0,262	807	0,55	0,576	536	0,56	0,570	795	0,55	0,576
19	★	50	★	MIX	BM	2	3	★	0,01	2	807	1,42	0,242	807	4,83	0,008	535	4,53	0,011	794	4,83	0,008
20	★	50	★	MIX	BM	2	5	★	0,01	2	807	0,41	0,662	807	2,08	0,126	537	1,98	0,139	802	2,08	0,126
21	★	100	★	2PX	BM	1	3	★	0,01	2	807	0,51	0,600	807	2,57	0,078	537	2,58	0,077	801	2,57	0,078
22	★	100	★	2PX	BM	1	5	★	0,01	2	807	0,21	0,815	807	0,46	0,631	538	0,47	0,629	805	0,46	0,631
23	★	100	★	2PX	BM	1	10	★	0,01	2	807	0,18	0,833	807	0,29	0,745	537	0,31	0,734	800	0,29	0,745
24	★	100	★	2PX	BM	2	3	★	0,01	2	807	0,38	0,681	807	4,08	0,017	537	4,11	0,017	802	4,08	0,017
25	★	100	★	2PX	BM	2	5	★	0,01	2	807	0,33	0,720	807	1,29	0,277	537	1,32	0,268	800	1,29	0,277
26	★	100	★	MIX	BM	1	3	★	0,01	2	807	1,32	0,267	807	5,26	0,005	536	5,07	0,007	794	5,26	0,005
27	★	100	★	MIX	BM	1	5	★	0,01	2	807	1,18	0,307	807	1,24	0,289	537	1,33	0,265	799	1,24	0,289
28	★	100	★	MIX	BM	1	10	★	0,01	2	807	1,95	0,142	807	2,06	0,128	535	2,07	0,128	792	2,06	0,128
29	★	100	★	MIX	BM	2	3	★	0,01	2	807	0,12	0,890	807	5,59	0,004	538	5,64	0,004	805	5,59	0,004
30	★	100	★	MIX	BM	2	5	★	0,01	2	807	0,11	0,901	807	1,52	0,220	537	1,60	0,203	802	1,52	0,220

Tab. D.42: Podsumowanie wyników jednoczynnikowej analizy wariancji dla $\tilde{G}\tilde{A}$ i $\tilde{S}\tilde{A}$ w $\mathbb{H}\tilde{A}$ (c.d.)

#	$\overline{GA}/\tilde{\Lambda}$		$\mathcal{P}$	$g_{\max}$	α_{GA}	β_{SA}	Parametry $\mathbb{H}\tilde{A}$				Test Levene'a			Test ANOVA		Test Welch'a			Test Browna-Forsythe'a				
							C	S	N	$\Delta_{\max}$	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_W	$p(H_0)$	df2	F_{BF}	$p(H_0)$
31	★	200	★	★	2PX	BM	1	3	★	0,01	2	807	0,21	0,812	807	3,72	0,025	538	3,60	0,028	804	3,72	0,025
32	★	200	★	★	2PX	BM	1	5	★	0,01	2	807	0,29	0,752	807	0,40	0,673	538	0,40	0,673	806	0,40	0,673
33	★	200	★	★	2PX	BM	1	10	★	0,01	2	807	1,78	0,170	807	3,03	0,049	535	2,88	0,057	790	3,03	0,049
34	★	200	★	★	2PX	BM	2	3	★	0,01	2	807	0,88	0,417	807	4,72	0,009	537	4,47	0,012	800	4,72	0,009
35	★	200	★	★	2PX	BM	2	5	★	0,01	2	807	0,50	0,605	807	0,91	0,402	537	0,92	0,399	801	0,91	0,402
36	★	200	★	★	MIX	BM	1	3	★	0,01	2	807	0,10	0,901	807	1,33	0,266	538	1,36	0,258	806	1,33	0,266
37	★	200	★	★	MIX	BM	1	5	★	0,01	2	807	0,25	0,777	807	1,85	0,158	538	1,84	0,159	807	1,85	0,158
38	★	200	★	★	MIX	BM	1	10	★	0,01	2	807	1,29	0,277	807	1,09	0,338	536	1,10	0,334	799	1,09	0,338
39	★	200	★	★	MIX	BM	2	3	★	0,01	2	807	0,78	0,457	807	6,27	0,002	538	6,02	0,003	804	6,27	0,002
40	★	200	★	★	MIX	BM	2	5	★	0,01	2	807	0,32	0,725	807	0,95	0,389	537	0,97	0,381	799	0,95	0,389
41	★	250	★	★	2PX	BM	1	3	★	0,01	2	807	0,58	0,562	807	2,95	0,053	537	3,08	0,047	801	2,95	0,053
42	★	250	★	★	2PX	BM	1	5	★	0,01	2	807	1,17	0,312	807	0,93	0,396	537	0,89	0,413	804	0,93	0,396
43	★	250	★	★	2PX	BM	1	10	★	0,01	2	807	5,62	0,004	807	9,88	<0,001	534	8,68	<0,001	777	9,88	<0,001
44	★	250	★	★	2PX	BM	2	3	★	0,01	2	807	1,57	0,208	807	6,00	0,003	537	5,79	0,003	803	6,00	0,003
45	★	250	★	★	2PX	BM	2	5	★	0,01	2	807	0,29	0,747	807	0,65	0,524	538	0,66	0,518	806	0,65	0,524
46	★	250	★	★	MIX	BM	1	3	★	0,01	2	807	0,29	0,748	807	2,34	0,097	537	2,24	0,108	803	2,34	0,097
47	★	250	★	★	MIX	BM	1	5	★	0,01	2	807	0,13	0,878	807	0,57	0,566	538	0,59	0,558	805	0,57	0,566
48	★	250	★	★	MIX	BM	1	10	★	0,01	2	807	9,31	<0,001	807	7,02	<0,001	528	6,54	0,002	744	7,02	<0,001
49	★	250	★	★	MIX	BM	2	3	★	0,01	2	807	0,69	0,500	807	3,99	0,019	538	4,05	0,018	806	3,99	0,019
50	★	250	★	★	MIX	BM	2	5	★	0,01	2	807	0,01	0,994	807	1,32	0,268	537	1,28	0,280	801	1,32	0,268
51	★	500	★	★	2PX	BM	1	3	★	0,01	2	807	3,95	0,020	807	1,47	0,230	530	1,84	0,159	745	1,47	0,230
52	★	500	★	★	2PX	BM	1	5	★	0,01	2	807	7,35	<0,001	807	0,96	0,383	532	0,93	0,394	758	0,96	0,383
53	★	500	★	★	2PX	BM	1	10	★	0,01	2	807	19,20	<0,001	807	16,64	<0,001	526	15,11	<0,001	720	16,64	<0,001
54	★	500	★	★	2PX	BM	2	3	★	0,01	2	807	0,83	0,438	807	2,37	0,095	535	2,43	0,089	788	2,37	0,095
55	★	500	★	★	2PX	BM	2	5	★	0,01	2	807	9,31	<0,001	807	3,01	0,050	528	2,44	0,088	727	3,01	0,050
56	★	500	★	★	MIX	BM	1	3	★	0,01	2	807	0,13	0,878	807	2,82	0,060	538	2,82	0,060	806	2,82	0,060
57	★	500	★	★	MIX	BM	1	5	★	0,01	2	807	0,48	0,622	807	0,08	0,923	537	0,08	0,923	804	0,08	0,923
58	★	500	★	★	MIX	BM	1	10	★	0,01	2	807	7,51	<0,001	807	7,14	<0,001	529	7,01	<0,001	766	7,14	<0,001
59	★	500	★	★	MIX	BM	2	3	★	0,01	2	807	5,78	0,003	807	12,50	<0,001	529	12,76	<0,001	765	12,50	<0,001
60	★	500	★	★	MIX	BM	2	5	★	0,01	2	807	0,45	0,635	807	0,89	0,413	536	0,93	0,397	797	0,89	0,413

Tab. D.43: Podsumowanie wyników testów *post-hoc* dla $\tilde{G}\tilde{A}$ i $\tilde{S}\tilde{A}$ w $\mathbb{H}\tilde{A}$. W zestawieniu przedstawiono jedynie $\tilde{G}\tilde{A}$, wartości pozostałych zmiennych parametrów $g_{\max}$, $\tilde{S}\tilde{A}$, N wynikają z ograniczenia liczby budowanych rozwiązań ($\tilde{\lambda} = 20\ 000$). Wyniki analizy wariancji wraz ze stałymi wartościami parametrów $\mathbb{H}\tilde{A}$ dla poniższych porównań przedstawiono w tab. D.42 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla $\tilde{G}\tilde{A} =$			Grupy jednorodne według $\tilde{G}\tilde{A}$		
	5 000	10 000	15 000	Tukey (HSD)	Tamhane (T2)	Games-Howell (GH)
1	0,55	0,54	0,68	[10 000 5 000 15 000]	[10 000 5 000 15 000]	[10 000 5 000 15 000]
2	0,68	0,73	0,87	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
3	1,05	0,96	1,02	[10 000 15 000 5 000]	[10 000 15 000 5 000]	[10 000 15 000 5 000]
4	0,49	0,52	0,67	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
5	0,69	0,67	0,77	[10 000 5 000 15 000]	[10 000 5 000 15 000]	[10 000 5 000 15 000]
6	0,54	0,51	0,67	[10 000 5 000 15 000]	[10 000 5 000 15 000]	[10 000 5 000 15 000]
7	0,74	0,70	0,89	[10 000 5 000 15 000]	[10 000 5 000 15 000]	[10 000 5 000 15 000]
8	1,03	0,99	1,07	[10 000 5 000 15 000]	[10 000 5 000 15 000]	[10 000 5 000 15 000]
9	0,49	0,53	0,70	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
10	0,66	0,62	0,86	[10 000 5 000 15 000]	[10 000 5 000 15 000]	[10 000 5 000 15 000]
11	0,44	0,45	0,51	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
12	0,62	0,64	0,61	[15 000 5 000 10 000]	[15 000 5 000 10 000]	[15 000 5 000 10 000]
13	0,86	0,78	0,78	[15 000 10 000 5 000]	[15 000 10 000 5 000]	[15 000 10 000 5 000]
14	0,42	0,46	0,53	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
15	0,59	0,59	0,61	[10 000 5 000 15 000]	[10 000 5 000 15 000]	[10 000 5 000 15 000]
16	0,45	0,55	0,62	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
17	0,61	0,64	0,73	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
18	0,91	0,83	0,88	[10 000 15 000 5 000]	[10 000 15 000 5 000]	[10 000 15 000 5 000]
19	0,44	0,47	0,61	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
20	0,59	0,62	0,72	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
21	0,42	0,46	0,54	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
22	0,56	0,58	0,61	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
23	0,71	0,68	0,67	[15 000 10 000 5 000]	[15 000 10 000 5 000]	[15 000 10 000 5 000]
24	0,39	0,43	0,53	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
25	0,48	0,51	0,56	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
26	0,43	0,46	0,60	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]
27	0,63	0,62	0,71	[10 000 5 000 15 000]	[10 000 5 000 15 000]	[10 000 5 000 15 000]
28	0,86	0,77	0,73	[15 000 10 000 5 000]	[15 000 10 000 5 000]	[15 000 10 000 5 000]
29	0,41	0,46	0,58	[5 000 10 000 15 000]	[5 000 10 000 15 000]	[5 000 10 000 15 000]

Tab. D.43: Podsumowanie wyników wybranych testów *post-hoc* dla $\tilde{G}\tilde{A}$ i $\tilde{S}\tilde{A}$ w $\mathbb{H}\tilde{A}$ (c.d.)

#	Wartość $\bar{\epsilon}[\%]$ dla $\tilde{G}\tilde{A} =$			Tukey (HSD)			Tamhane (T2)			Grupy jednorodne według $\tilde{G}\tilde{A}/\tilde{\Lambda}$		
	5 000	10 000	15 000							Games-Howell (GH)		
30	0,56	0,57	0,65	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
31	0,39	0,38	0,49	[10 000 5 000 15 000]			[10 000 5 000 15 000]			[10 000 5 000 15 000]		
32	0,50	0,48	0,52	[10 000 5 000 15 000]			[10 000 5 000 15 000]			[10 000 5 000 15 000]		
33	0,70	0,61	0,57	[15 000 10 000 5 000]			[15 000 10 000 5 000]			[15 000 10 000 5 000]		
34	0,34	0,37	0,46	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
35	0,46	0,45	0,51	[10 000 5 000 15 000]			[10 000 5 000 15 000]			[10 000 5 000 15 000]		
36	0,45	0,47	0,53	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
37	0,56	0,64	0,67	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
38	0,81	0,74	0,71	[15 000 10 000 5 000]			[15 000 10 000 5 000]			[15 000 10 000 5 000]		
39	0,39	0,45	0,57	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
40	0,53	0,60	0,61	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
41	0,41	0,38	0,49	[10 000 5 000 15 000]			[10 000 5 000 15 000]			[10 000 5 000 15 000]		
42	0,53	0,53	0,59	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
43	0,83	0,60	0,59	[15 000 10 000 5 000]			[15 000 10 000 5 000]			[15 000 10 000 5 000]		
44	0,36	0,36	0,50	[10 000 5 000 15 000]			[10 000 5 000 15 000]			[10 000 5 000 15 000]		
45	0,51	0,46	0,50	[10 000 15 000 5 000]			[10 000 15 000 5 000]			[10 000 15 000 5 000]		
46	0,42	0,47	0,52	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
47	0,58	0,58	0,63	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
48	0,93	0,76	0,67	[15 000 10 000 5 000]			[15 000 10 000 5 000]			[15 000 10 000 5 000]		
49	0,41	0,49	0,56	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
50	0,52	0,55	0,61	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
51	0,45	0,40	0,48	[10 000 5 000 15 000]			[10 000 5 000 15 000]			[10 000 5 000 15 000]		
52	0,61	0,54	0,58	[10 000 15 000 5 000]			[10 000 15 000 5 000]			[10 000 15 000 5 000]		
53	0,97	0,75	0,62	[15 000 10 000 5 000]			[15 000 10 000 5 000]			[15 000 10 000 5 000]		
54	0,39	0,39	0,47	[10 000 5 000 15 000]			[10 000 5 000 15 000]			[10 000 5 000 15 000]		
55	0,59	0,49	0,48	[15 000 10 000 5 000]			[15 000 10 000 5 000]			[15 000 10 000 5 000]		
56	0,45	0,51	0,58	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
57	0,66	0,68	0,69	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
58	1,07	0,89	0,80	[15 000 10 000 5 000]			[15 000 10 000 5 000]			[15 000 10 000 5 000]		
59	0,37	0,48	0,63	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		
60	0,59	0,62	0,67	[5 000 10 000 15 000]			[5 000 10 000 15 000]			[5 000 10 000 15 000]		

Tab. D.44: Podsumowanie wyników jednoczynnikowej analizy wariancji dla C w HIA. Wartość N jest zmienna ze względu na zmienne C i stałe ograniczenie $\tilde{S}\tilde{A} = 15\ 000$. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry HIA										Test Levene'a			Test ANOVA			Test Welch'a			Test Browna-Forsythe'a		
	$\tilde{G}\tilde{A}/\tilde{\Lambda}$	$\tilde{\mathcal{P}}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$	df1	df2	L	$p(H_0)$	df2	F	$p(H_0)$	df2	F_W	$p(H_0)$	df2	F_{BF}	$p(H_0)$
1	0,25	25	200	2PX	BM	★	3	★	0,01	4	1345	2,55	0,037	1345	7,40	<0,001	671	8,05	<0,001	1319	7,40	<0,001
2	0,25	25	200	2PX	BM	★	5	★	0,01	4	1345	0,80	0,527	1345	3,53	0,007	672	3,58	0,007	1340	3,53	0,007
3	0,25	50	100	2PX	BM	★	3	★	0,01	4	1345	0,13	0,973	1345	5,59	<0,001	672	5,54	<0,001	1332	5,59	<0,001
4	0,25	50	100	2PX	BM	★	5	★	0,01	4	1345	0,29	0,883	1345	1,04	0,385	672	0,97	0,421	1327	1,04	0,385
5	0,25	100	50	2PX	BM	★	3	★	0,01	4	1345	1,87	0,114	1345	8,65	<0,001	672	9,00	<0,001	1330	8,65	<0,001
6	0,25	100	50	2PX	BM	★	5	★	0,01	4	1345	2,15	0,072	1345	5,12	<0,001	672	5,40	<0,001	1321	5,12	<0,001
7	0,25	200	25	2PX	BM	★	3	★	0,01	4	1345	6,44	<0,001	1345	15,26	<0,001	670	16,98	<0,001	1278	15,26	<0,001
8	0,25	200	25	2PX	BM	★	5	★	0,01	4	1345	6,00	<0,001	1345	10,37	<0,001	670	11,07	<0,001	1286	10,37	<0,001
9	0,25	250	20	2PX	BM	★	3	★	0,01	4	1345	3,51	0,007	1345	11,30	<0,001	671	12,26	<0,001	1319	11,30	<0,001
10	0,25	250	20	2PX	BM	★	5	★	0,01	4	1345	4,15	0,002	1345	8,56	<0,001	671	8,99	<0,001	1286	8,56	<0,001
11	0,25	500	10	2PX	BM	★	3	★	0,01	4	1345	10,27	<0,001	1345	17,70	<0,001	666	21,31	<0,001	1222	17,70	<0,001
12	0,25	500	10	2PX	BM	★	5	★	0,01	4	1345	5,67	<0,001	1345	13,03	<0,001	670	14,28	<0,001	1273	13,03	<0,001

Tab. D.45: Podsumowanie wyników wybranych testów *post-hoc* dla C w HIA. Wartość N jest zmienna ze względu na zmienne C i stałe ograniczenie $\tilde{S}\tilde{A} = 15\ 000$. Wyniki analizy wariancji wraz ze stałymi wartościami parametrów HIA dla poniższych porównań przedstawiono w tab. D.44 (zgodnie z oznaczeniem w #).

#	Wartość $\bar{\epsilon}[\%]$ dla $C =$					Grupy jednorodne według C			
	1	2	3	4	5	Tukey (HSD)	Tamhane (T2)	Games-Howell (GH)	
1	0,55	0,49	0,74	0,79	0,71	[2 1] [5 3 4]	[2 1] [5 3 4]	[2 1] [5 3 4]	
2	0,68	0,69	0,89	0,85	0,82	[1 2 5 4 3]	[1 2 5 4 3]	[1 2 5 4 3]	
3	0,44	0,42	0,57	0,59	0,63	[2 1 3 4 5]	[2 1 3 4 5]	[2 1 3 4 5]	
4	0,62	0,59	0,72	0,65	0,65	[2 1 5 4 3]	[2 1 5 4 3]	[2 1 5 4 3]	
5	0,42	0,39	0,56	0,63	0,59	[2 1] [3 5 4]	[2 1] [3 5 4]	[2 1] [3 5 4]	
6	0,56	0,48	0,71	0,64	0,64	[2 1 4 5 3]	[2 1 4 5 3]	[2 1 4 5 3]	
7	0,39	0,34	0,60	0,63	0,60	[2 1] [3 5 4]	[2 1] [3 5 4]	[2 1] [3 5 4]	
8	0,50	0,46	0,73	0,71	0,68	[2 1] [5 4 3]	[2 1] [5 4 3]	[2 1] [5 4 3]	
9	0,41	0,36	0,60	0,62	0,62	[2 1] [3 5 4]	[2 1] [3 5 4]	[2 1] [3 5 4]	
10	0,53	0,51	0,76	0,71	0,70	[2 1] [5 4 3]	[2 1] [5 4 3]	[2 1] [5 4 3]	
11	0,45	0,39	0,74	0,79	0,78	[2 1] [3 5 4]	[2 1] [3 5 4]	[2 1] [3 5 4]	
12	0,61	0,59	0,96	0,92	0,90	[2 1] [5 4 3]	[2 1] [5 4 3]	[2 1] [5 4 3]	

Tab. D.46: Podsumowanie wyników jednoczynnikowej analizy wariancji dla $\Delta_{\max}$ w H_A. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry H _A					E[$\%$] dla $\Delta_{\max}$		df1	Test Levene'a		Test ANOVA		Test Welch'a								
	$\bar{G}_A/\bar{\Lambda}$	$\mathcal{P}$	$g_{\max}$	α_{GA}	β_{SA}	C	S		N	$\Delta_{\max}$	df2	L	F	p(H ₀)	df2	F _W	p(H ₀)				
1	0,25	50	100	2PX	BM	2	3	1814	★	0,42	0,54	1	538	10,45	0,001	538	6,26	0,013	462	6,26	0,013
2	0,25	100	50	2PX	BM	2	3	1814	★	0,39	0,53	1	538	8,18	0,004	538	12,08	<0,001	494	12,08	<0,001
3	0,25	200	25	2PX	BM	2	3	1814	★	0,34	0,57	1	538	0,14	0,706	538	33,14	<0,001	537	33,14	<0,001
4	0,25	500	10	2PX	BM	2	3	1814	★	0,39	0,60	1	538	0,08	0,781	538	19,07	<0,001	536	19,07	<0,001
5	0,25	50	100	MIX	BM	2	3	1814	★	0,44	0,54	1	538	12,98	<0,001	538	3,67	0,056	444	3,67	0,056
6	0,25	100	50	MIX	BM	2	3	1814	★	0,40	0,59	1	538	2,98	0,085	538	14,49	<0,001	504	14,49	<0,001
7	0,25	200	25	MIX	BM	2	3	1814	★	0,39	0,59	1	538	1,23	0,268	538	18,64	<0,001	508	18,64	<0,001
8	0,25	500	10	MIX	BM	2	3	1814	★	0,37	0,58	1	538	0,11	0,738	538	22,97	<0,001	538	22,97	<0,001
9	0,50	50	200	2PX	BM	2	3	1210	★	0,46	0,69	1	538	1,36	0,245	538	19,91	<0,001	526	19,91	<0,001
10	0,50	100	100	2PX	BM	2	3	1210	★	0,43	0,65	1	538	1,19	0,276	538	23,02	<0,001	496	23,02	<0,001
11	0,50	200	50	2PX	BM	2	3	1210	★	0,37	0,69	1	538	0,99	0,321	538	59,14	<0,001	538	59,14	<0,001
12	0,50	500	20	2PX	BM	2	3	1210	★	0,39	0,73	1	538	9,21	0,003	538	58,46	<0,001	503	58,46	<0,001
13	0,50	50	200	MIX	BM	2	3	1210	★	0,47	0,66	1	538	8,27	0,004	538	16,48	<0,001	495	16,48	<0,001
14	0,50	100	100	MIX	BM	2	3	1210	★	0,46	0,65	1	538	3,97	0,047	538	16,51	<0,001	513	16,51	<0,001
15	0,50	200	50	MIX	BM	2	3	1210	★	0,45	0,77	1	538	0,10	0,756	538	44,81	<0,001	537	44,81	<0,001
16	0,50	500	20	MIX	BM	2	3	1210	★	0,48	0,71	1	538	0,56	0,454	538	22,08	<0,001	531	22,08	<0,001
17	0,75	50	300	2PX	BM	2	3	605	★	0,53	0,85	1	538	0,25	0,615	538	44,47	<0,001	536	44,47	<0,001
18	0,75	100	150	2PX	BM	2	3	605	★	0,53	0,84	1	538	1,64	0,201	538	37,84	<0,001	537	37,84	<0,001
19	0,75	200	75	2PX	BM	2	3	605	★	0,46	0,81	1	538	1,17	0,280	538	61,34	<0,001	538	61,34	<0,001
20	0,75	500	30	2PX	BM	2	3	605	★	0,47	0,96	1	538	5,92	0,015	538	120,33	<0,001	527	120,33	<0,001
21	0,75	50	300	MIX	BM	2	3	605	★	0,61	0,95	1	538	2,06	0,152	538	36,05	<0,001	517	36,05	<0,001
22	0,75	100	150	MIX	BM	2	3	605	★	0,58	0,92	1	538	0,31	0,579	538	43,10	<0,001	538	43,10	<0,001
23	0,75	200	75	MIX	BM	2	3	605	★	0,57	0,94	1	538	0,19	0,668	538	50,53	<0,001	538	50,53	<0,001
24	0,75	500	30	MIX	BM	2	3	605	★	0,63	1,08	1	538	1,87	0,172	538	57,75	<0,001	537	57,75	<0,001

Tab. D.47: Podsumowanie wyników jednoczynnikowej analizy wariancji dla α w $\mathbb{H}_A$. Wielkość próby w każdej komórce wynosi $n = 270$.

#	Parametry $\mathbb{H}_A$							$\bar{\epsilon}[\%]$ dla α		df1	Test Levene'a			Test ANOVA			Test Welch'a				
	$\hat{\sigma}_A/\hat{\Lambda}$	$\hat{\phi}$	$g_{\max}$	α_{GA}	β_{SA}	C	S	N	$\Delta_{\max}$		2P%	MIX	df2	L	p(H ₀)	df2	F	p(H ₀)	df2	F _w	p(H ₀)
1	0,25	25	200	★	BM	2	3	1814	0,01	0,49	0,49	1	538	0,74	0,389	538	0,00	0,964	526	0,00	0,964
2	0,25	50	100	★	BM	2	3	1814	0,01	0,42	0,44	1	538	0,24	0,621	538	0,10	0,748	535	0,10	0,748
3	0,25	100	50	★	BM	2	3	1814	0,01	0,39	0,41	1	538	0,74	0,390	538	0,12	0,728	529	0,12	0,728
4	0,25	200	25	★	BM	2	3	1814	0,01	0,34	0,39	1	538	2,36	0,125	538	1,32	0,251	515	1,32	0,251
5	0,25	250	20	★	BM	2	3	1814	0,01	0,36	0,41	1	538	0,89	0,346	538	0,90	0,342	525	0,90	0,342
6	0,25	500	10	★	BM	2	3	1814	0,01	0,39	0,37	1	538	0,63	0,428	538	0,24	0,624	535	0,24	0,624
7	0,50	25	400	★	BM	2	3	1210	0,01	0,52	0,53	1	538	0,01	0,922	538	0,02	0,876	531	0,02	0,876
8	0,50	50	200	★	BM	2	3	1210	0,01	0,46	0,47	1	538	0,06	0,815	538	0,07	0,799	537	0,07	0,799
9	0,50	100	100	★	BM	2	3	1210	0,01	0,43	0,46	1	538	0,50	0,479	538	0,26	0,608	538	0,26	0,608
10	0,50	200	50	★	BM	2	3	1210	0,01	0,37	0,45	1	538	5,29	0,022	538	3,30	0,070	524	3,30	0,070
11	0,50	250	40	★	BM	2	3	1210	0,01	0,36	0,49	1	538	10,10	0,002	538	6,83	0,009	510	6,83	0,009
12	0,50	500	20	★	BM	2	3	1210	0,01	0,39	0,48	1	538	8,00	0,005	538	4,19	0,041	490	4,19	0,041
13	0,75	25	600	★	BM	2	3	605	0,01	0,67	0,70	1	538	0,07	0,790	538	0,33	0,569	532	0,33	0,569
14	0,75	50	300	★	BM	2	3	605	0,01	0,53	0,61	1	538	5,98	0,015	538	2,10	0,148	516	2,10	0,148
15	0,75	100	150	★	BM	2	3	605	0,01	0,53	0,58	1	538	0,25	0,617	538	0,90	0,343	538	0,90	0,343
16	0,75	200	75	★	BM	2	3	605	0,01	0,46	0,57	1	538	3,44	0,064	538	4,46	0,035	527	4,46	0,035
17	0,75	250	60	★	BM	2	3	605	0,01	0,50	0,56	1	538	4,25	0,040	538	1,64	0,201	532	1,64	0,201
18	0,75	500	30	★	BM	2	3	605	0,01	0,47	0,63	1	538	9,47	0,002	538	9,75	0,002	490	9,75	0,002

Oznaczenia

Symbol	Znaczenie
$ZR_{i \rightarrow k}^{\text{all}}$	oznaczenie zależności kolejnościowej w relacji typu zakończenie-rozpoczęcie od czynności i do czynności j
$ZR_{i \rightarrow k}^{\text{imi}}$	oznaczenie bezpośredniej zależności kolejnościowej w relacji typu zakończenie-rozpoczęcie od czynności i do czynności j
$ZR_{i \rightarrow k}^{\text{max}}$	maksymalny dopuszczalny odstęp czasowy w relacji typu zakończenie-rozpoczęcie od i -tej do k -tej czynności
$ZR_{i \rightarrow k}^{\text{min}}$	minimalny wymagany odstęp czasowy w relacji typu zakończenie-rozpoczęcie od i -tej do k -tej czynności
RR	relacja typu rozpoczęcie–rozpoczęcie
RZ	relacja typu rozpoczęcie–zakończenie
ZR	relacja typu zakończenie–rozpoczęcie
ZZ	relacja typu zakończenie–zakończenie
ϵ	względne odchylenie od najlepszego znanego rozwiązania dla wybranego problemu
$\bar{\epsilon}$	średnie względne odchylenie od najlepszych znanych rozwiązań dla wybranego problemu lub grupy problemów odnalezionych przez wybraną procedurę lub grupę procedur
Ω	zbiór czynności do wykonania
ω_i	oznaczenie i -tej czynności
ω_i^π	identyfikator projektu w ramach którego realizowana jest i -ta czynność
$\tilde{\Omega}$	liczba czynności
$\omega_i^\oplus$	zbiór wszystkich następników i -tej czynności
$\omega_i^\ominus$	zbiór wszystkich poprzedników i -tej czynności
ω_i^+	zbiór bezpośrednich następników i -tej czynności
ω_i^-	zbiór bezpośrednich poprzedników i -tej czynności
$\tilde{\omega}_i^\oplus$	liczba wszystkich następników i -tej czynności
$\tilde{\omega}_i^\ominus$	liczba wszystkich poprzedników i -tej czynności
$\tilde{\omega}_i^+$	liczba bezpośrednich następników i -tej czynności
$\tilde{\omega}_i^-$	liczba bezpośrednich poprzedników i -tej czynności
$\mathcal{M}_i^\omega$	zbiór sposobów wykonania i -tej czynności
$\omega[i, m, \mathcal{T}]$	czas realizacji i -tej czynności w m -ty sposób
$\tilde{\mathcal{M}}_i^\omega$	liczba możliwych sposobów wykonania i -tej czynności
$\mathcal{F}_i^\omega$	termin zakończenia realizacji i -tej czynności
$\mathcal{S}_i^{\text{max}}$	najpóźniejszy termin rozpoczęcia i -tej czynności

Symbol	Znaczenie
$S_i^{\min}$	najwcześniejszy termin rozpoczęcia i -tej czynności
Q_i^{ω}	wartość priorytetu i -tej czynności
S_i^{ω}	termin rozpoczęcia realizacji i -tej czynności
$\omega[i, m, t, \mathcal{E}]$	koszt (nakład) realizacji i -tej czynności w m -ty sposób w t -tym (względny) okresie realizacji
$\omega[i, m, v_r]$	zapotrzebowanie na r -ty zasób nieodnawialny dla zrealizowania i -tej czynności w m -ty sposób
μ_i	sposób, w który ma być wykonana i -ta czynność
$\omega[i, m, \rho_r]$	zapotrzebowanie na r -ty zasób odnawialny dla zrealizowania i -tej czynności w m -ty sposób
$\mathcal{I}_i^{\omega}$	przychody związane z zakończeniem i -tej czynności
$\omega[i, m, \mathcal{E}]$	wielkość wydatków związana z wykonaniem i -tej czynności w m -ty sposób
$\omega[i, m, \mathcal{E}_t]$	wielkość wydatków związana z wykonaniem i -tej czynności w m -ty sposób w t -tym okresie jej realizacji
$\omega[i, m, \mathcal{E}f]$	całkowity wydatek (koszt i nakład) stały realizacji i -tej czynności w m -ty sposób
$\omega[i, m, t, \mathcal{E}f]$	całkowity koszt (nakład) stały realizacji i -tej czynności w m -ty sposób w okresie t
$\omega[i, m, \mathcal{E}f\mathcal{F}]$	wielkość stałych kosztów (nakładów) ponoszonych wraz z zakończeniem realizacji i -tej czynności w m -ty sposób
$\omega[i, m, \mathcal{E}f\mathcal{P}]$	wielkość stałych kosztów (nakładów) ponoszonych w każdym okresie realizacji i -tej czynności w m -ty sposób
$\omega[i, m, \mathcal{E}f\mathcal{S}]$	wielkość stałych kosztów (nakładów) ponoszonych wraz z rozpoczęciem realizacji i -tej czynności w m -ty sposób
$\omega[i, m, \mathcal{E}_{\psi}]$	koszt (nakład) wykorzystania zasobów do realizacji i -tej czynności w m -ty sposób
$\omega[i, m, \mathcal{E}_v]$	koszt (nakład) wykorzystania zasobów nieodnawialnych do realizacji i -tej czynności w m -ty sposób
$\omega[i, m, t, \mathcal{E}_v]$	koszt (nakład) wykorzystania zasobów nieodnawialnych dla realizacji i -tej czynności w m -ty sposób w okresie t
$\omega[i, m, \mathcal{E}_{\rho}]$	koszt (nakład) wykorzystania zasobów odnawialnych do realizacji i -tej czynności w m -ty sposób
$\omega[i, m, t, \mathcal{E}_{\rho}]$	koszt (nakład) wykorzystania zasobów odnawialnych dla realizacji i -tej czynności w m -ty sposób w okresie t
$\omega[i, m, \mathcal{E}]$	całkowite wydatki (koszty i nakłady) realizacji i -tej czynności w m -ty sposób
$v(i, r)$	funkcja zwracająca 1 jeżeli do realizacji i -tej czynności potrzebny jest r -ty zasób odnawialny oraz 0 w przeciwnym przypadku
$\omega[i, m, CF]$	przepływy pieniężne związane z wykonaniem i -tej czynności w m -ty sposób
$\omega[i, m, NPV^d]$	zdyskontowane (przy stopie dyskontowej d) skumulowane przepływy pieniężne związane z realizacją i -tej czynności w m -ty sposób
Ξ	zbiór relacji pomiędzy czynnościami
$\mathcal{L}_{p \rightarrow n}^{\min}$	maksymalny dopuszczalny odstęp czasowy w relacji od p -tej do n -tej czynności
$\mathcal{L}_{p \rightarrow n}^{\max}$	minimalny wymagany odstęp czasowy w relacji od p -tej do n -tej czynności
Ψ	zbiór zasobów $\Psi = \Psi_N \cup \Psi_R$
$\tilde{\Psi}$	liczba zasobów
Ψ_R	zbiór zasobów odnawialnych

Symbol	Znaczenie
ρ_r	oznaczenie r -tego zasobu odnawialnego
$\rho[r, t, \mathcal{A}]$	liczba jednostek r -tego zasobu odnawialnego nieprzydzielonych w okresie t
$\rho[r, t, C]$	dostępna liczba jednostek r -tego zasobu odnawialnego w okresie t
$\rho[r, t, \mathcal{U}]$	liczba jednostek r -tego zasobu odnawialnego używanych w okresie t
$\tilde{\Psi}_R$	liczba zasobów odnawialnych
$\mathcal{E}f\mathcal{F}_r^o$	stały koszt użycia r -tego zasobu odnawialnego ponoszony wraz z zakończeniem czynności
$\mathcal{E}f\mathcal{P}_r^o$	stały koszt (nakład) użycia r -tego zasobu odnawialnego przez jeden okres czasu
$\mathcal{E}f\mathcal{S}_r^o$	stały koszt użycia r -tego zasobu odnawialnego ponoszony wraz z rozpoczęciem czynności
$\bar{\rho}_r$	średnia dostępna liczba jednostek r -tego zasobu odnawialnego
$\mathcal{E}v\mathcal{F}_r^o$	zmienny koszt (nakład) użycia jednostki r -tego zasobu odnawialnego ponoszony wraz z zakończeniem czynności
$\mathcal{E}v\mathcal{P}_r^o$	zmienny koszt (nakład) użycia jednostki r -tego zasobu odnawialnego przez jeden okres czasu
$\mathcal{E}v\mathcal{S}_r^o$	zmienny koszt (nakład) użycia jednostki r -tego zasobu odnawialnego ponoszony wraz z rozpoczęciem czynności
Ψ_N	zbiór zasobów nieodnawialnych
v_r	oznaczenie r -tego zasobu nieodnawialnego
C_r^v	dostępna liczba jednostek r -tego zasobu nieodnawialnego
$\rho[r, t, \mathcal{U}]$	liczba jednostek r -tego zasobu nieodnawialnego zużytego do chwili t
$\tilde{\Psi}_N$	liczba zasobów nieodnawialnych
$\mathcal{E}f\mathcal{F}_r^v$	stały koszt (nakład) użycia r -tego zasobu nieodnawialnego ponoszony wraz z zakończeniem czynności
$\mathcal{E}f\mathcal{P}_r^v$	stały koszt (nakład) użycia r -tego zasobu nieodnawialnego przez jeden okres czasu
$\mathcal{E}f\mathcal{S}_r^v$	stały koszt (nakład) użycia r -tego zasobu nieodnawialnego ponoszony wraz z rozpoczęciem czynności
$\mathcal{E}v\mathcal{F}_r^v$	zmienny koszt (nakład) użycia jednostki r -tego zasobu nieodnawialnego ponoszony wraz z zakończeniem czynności
$\mathcal{E}v\mathcal{P}_r^v$	zmienny koszt (nakład) użycia jednostki r -tego zasobu nieodnawialnego przez jeden okres czasu
$\mathcal{E}v\mathcal{S}_r^v$	zmienny koszt (nakład) użycia jednostki r -tego zasobu nieodnawialnego ponoszony wraz z rozpoczęciem czynności
$\mathcal{E}f\mathcal{F}_r^\psi$	stały koszt (nakład) użycia r -tego zasobu ponoszony wraz z zakończeniem czynności
$\mathcal{E}f\mathcal{P}_r^\psi$	stały koszt (nakład) użycia r -tego zasobu przez jeden okres czasu
$\mathcal{E}f\mathcal{S}_r^\psi$	stały koszt (nakład) użycia r -tego zasobu ponoszony wraz z rozpoczęciem czynności
$\mathcal{E}v\mathcal{F}_r^\psi$	zmienny koszt (nakład) użycia jednostki r -tego zasobu ponoszony wraz z zakończeniem czynności
$\mathcal{E}v\mathcal{P}_r^\psi$	zmienny koszt (nakład) użycia jednostki r -tego zasobu przez jeden okres czasu
$\mathcal{E}v\mathcal{S}_r^\psi$	zmienny koszt (nakład) użycia jednostki r -tego zasobu ponoszony wraz z rozpoczęciem czynności

Symbol	Znaczenie
RS_r^ψ	wartość miernika RS dla r -tego zasobu
RS_r^ν	wartość miernika RS dla r -tego zasobu nieodnawialnego
RS_r^ρ	wartość miernika RS dla r -tego zasobu odnawialnego
$\bar{RS}^\nu$	średnia wartość RS dla zasobów nieodnawialnych
$\bar{RS}^\rho$	średnia wartość RS dla zasobów odnawialnych
Π	zbiór projektów
$\pi[i]$	oznaczenie i -tego projektu
Ω_i^π	zbiór czynności i -tego projektu
$S_{\pi i}^{\min}$	najwcześniejszy termin rozpoczęcia i -tego projektu
$\mathcal{F}_i^\pi$	termin zakończenia realizacji i -tego projektu
$\mathcal{S}_i^\pi$	termin rozpoczęcia realizacji i -tego projektu
$\mathcal{D}_i^\pi$	narzucony termin zakończenia i -tego projektu
$\mathcal{L}_i^\pi$	liczba okresów opóźnienia realizacji i -tego projektu
$\mathcal{EL}_i^\pi$	stawka kary za opóźnienie i -tego projektu o jeden okres czasu
$\mathcal{Ef}_i^\pi$	całkowite koszty (nakłady) stałe realizacji i -tego projektu
$\pi[i, t, \mathcal{Ef}]$	koszt (nakład) stały realizacji i -tego projektu w okresie t
$\mathcal{Ef}\mathcal{F}_i^\pi$	koszt (nakład) stały realizacji i -tego projektu w momencie zakończenia jego realizacji
$\mathcal{Ef}\mathcal{P}_i^\pi$	koszt (nakład) stały realizacji i -tego projektu w każdym okresie jego realizacji
$\mathcal{Ef}\mathcal{S}_i^\pi$	koszt (nakład) stały realizacji i -tego projektu w momencie rozpoczęcia jego realizacji
$\mathcal{E}_i^\pi$	koszt (nakład) całkowity realizacji i -tego projektu
$\mathcal{I}_i^\pi$	przychód z tytułu zrealizowania i -tego projektu w terminie $\mathcal{D}_i^\pi$
$\pi[i, t, \mathcal{I}]$	całkowite przychody z tytułu realizacji i -tego projektu otrzymane w chwili t
$\mathcal{I}_t$	wpływy w okresie t
$\mathcal{E}_t$	wydatki w okresie t
NCF_t	saldo przepływów pieniężnych w okresie t
$NPV_{t_{\max}}^d$	skumulowane zdyskontowane saldo przepływów pieniężnych (wartość zaktualizowana netto) przy stopie dyskontowej na poziomie d
NPV_t^d	wartość bieżąca przepływów pieniężnych w okresie t przy stopie dyskontowej na poziomie d
a_i	i -ty element zbioru alleli
$\mathcal{A}$	zbiór wartości alleli
$\mathcal{F}_i^p$	fenotyp i -tego osobnika w p -tej populacji
$\mathcal{G}_i^p$	genotyp i -tego osobnika w p -tej populacji
$\mathcal{G}_{\text{best}}^p$	najlepiej przystosowany osobnik w p -tej populacji
$\mathcal{P}_i^\star$	populacja tymczasowa powstała w efekcie operacji genetycznych na populacji początkowej w i -tym pokoleniu
$\mathcal{P}_i$	populacja osobników w i -tym pokoleniu
$\mathcal{M}_i$	pula rodzicielska w i -tym pokoleniu
Λ	funkcja celu

Symbol	Znaczenie
Δ	funkcja przystosowania
λ_i^p	wartość celu i -tego osobnika w p -tej populacji
$\bar{\lambda}^p$	średnia wartość celu osobników w p -tej populacji
δ_i^p	wartość przystosowania i -tego osobnika w p -tej populacji
α	operator krzyżowania
γ	operator inwersji
β	operator mutacji
p_α	prawdopodobieństwo krzyżowania
p_γ	prawdopodobieństwo inwersji
p_β	prawdopodobieństwo mutacji
$\mathcal{R}_i$	i -ty osobnik rodzicielski
ϕ	operator selekcji
$\mathcal{Z}$	zbiór osobników wylosowanych do turnieju
ζ	liczba osobników losowana do turnieju w selekcji turniejowej dla GA
$g_{\max}$	liczba pokoleń
$\tilde{\mathcal{P}}_p$	liczba osobników w p -tej populacji
M_m	długość listy tabu sposobów wykonania czynności w procedurze TS
M_p	długość listy tabu uszeregowania czynności w procedurze TS
$\tilde{\Lambda}$	liczba wywołań Λ
$\alpha(\mathcal{T})$	operacja łączenia rozwiązań ze zbioru $\mathcal{T}$ w procedurze SS
$\delta(s_1, s_2)$	odległość pomiędzy rozwiązaniami s_1 i s_2 w procedurze SS
$\mathcal{I}$	operacja ulepszania w procedurze SS
$\mathcal{RS}$	referencyjny zbiór rozwiązań w procedurze SS
$\sigma(\mathcal{RS})$	operacja losowania ze zbioru $\mathcal{RS}$ w procedurze SS
$\mathcal{T}$	próbny zbiór rozwiązań w procedurze SS
$\mathcal{L}_g$	procedura nauki w g -tym etapie procesu edukacji w PLA
$\mathcal{S}_g$	procedura selekcji w g -tym etapie procesu edukacji w PLA

Spis rysunków

2.1	Przykładowa sieć typu AON dla projektu z dwoma zasobami	9
2.2	Przykładowa sieć typu AOA dla projektu z rys. 2.1 z pominięciem informacji o zasobach	10
2.3	Przykładowa sieć typu AON z przepływami pieniężnymi	11
2.4	Przykładowa sieć typu AOA z uwzględnieniem przepływów pieniężnych	11
2.5	Przykładowa sieć typu AOA z uwzględnieniem przepływów pieniężnych powiązanych z realizacją czynności	11
2.6	Przykładowa sieć typu AON ze względnymi ograniczeniami czasowymi	12
2.7	Ograniczenia w modelach harmonogramowania projektów	15
3.1	Koszty w modelu cyklu życia projektu	32
3.2	Porównanie przepływów pieniężnych i efektywności dla wybranych rodzajów modeli płatności	34
3.3	Proces budowy harmonogramu bez uwzględnienia czynników ekonomicznych	39
3.4	Zmodyfikowany proces budowy harmonogramu	39
4.1	Składniki kosztów w modelu harmonogramowania realizacji projektów	44
5.1	Zależność pomiędzy procedurą budowy i optymalizacji harmonogramu	52
5.2	Rodzaje relacji pomiędzy przestrzenią parametrów i rozwiązań	53
6.1	Parametry składników kosztów w badanych problemach RCPS	74
6.2	Wpływ p_m na $\bar{\epsilon}$ w zależności od p_p dla SA	80
6.3	Wpływ β na $\bar{\epsilon}$ w zależności od C dla SA ($S = 5$; $p_p = 0,90$; $p_m = 0,02$; $h = 0$; $\Delta_{\max} = 0,2$).	81
6.4	Wpływ S na $\bar{\epsilon}$ w zależności od C dla SA ($\beta = \text{BM}$; $p_p = 0,90$; $p_m = 0,02$; $h = 0$; $\Delta_{\max} = 0,2$).	82
6.5	Wpływ $\Delta_{\max}$ na $\bar{\epsilon}$ w zależności od C dla SA ($S = 5$; $\beta = \text{BM}$; $p_p = 0,90$; $p_m = 0,02$; $h = 0$)	83
6.6	Wpływ $\tilde{\mathcal{P}}$ na $\bar{\epsilon}$ dla GA bez elityzmu w zależności od α ($p_\alpha = 0,9$) oraz β ($p_\beta = 0,1$).	84
6.7	Wpływ $\tilde{\mathcal{P}}$ na $\bar{\epsilon}$ dla GA z elityzmem w zależności od α ($p_\alpha = 0,9$) oraz β ($p_\beta = 0,1$).	85
6.8	Wpływ α ($p_\alpha = 0,9$) na $\bar{\epsilon}$ dla GA z elityzmem w zależności od $\tilde{\mathcal{P}}$ i β ($p_\beta = 0,1$).	85
6.9	Wpływ α ($p_\alpha = 0,9$) na $\bar{\epsilon}$ dla GA bez elityzmu w zależności od $\tilde{\mathcal{P}}$ i β ($p_\beta = 0,1$).	86
6.10	Wpływ β ($p_\beta = 0,1$) na $\bar{\epsilon}$ dla GA bez elityzmu w zależności od $\tilde{\mathcal{P}}$ i α ($p_\alpha = 0,9$).	87
6.11	Wpływ β ($p_\beta = 0,1$) na $\bar{\epsilon}$ dla GA z elityzmem w zależności od $\tilde{\mathcal{P}}$ i α ($p_\alpha = 0,9$).	87
6.12	Wpływ p_α i p_β na $\bar{\epsilon}$ dla GA z $\beta = \text{BM}$ ($\tilde{\mathcal{P}} = 200$; $g_{\max} = 100$)	88
6.13	Wpływ p_α i p_β na $\bar{\epsilon}$ dla GA z $\beta = \text{HM}$ ($\tilde{\mathcal{P}} = 200$; $g_{\max} = 100$)	89
6.14	Wpływ p_α i p_β na $\bar{\epsilon}$ dla GA z $\beta = \text{MM}$ ($\tilde{\mathcal{P}} = 200$; $g_{\max} = 100$)	89
6.15	Wpływ ζ na $\bar{\epsilon}$ dla GA z $\alpha = \text{MIX}$ ($p_\alpha = 0,9$) i $\beta = \text{MM}$ ($p_\beta = 0,1$).	90
6.16	Wpływ β na $\bar{\epsilon}$ dla TS przy $M_m = 10$ i $M_p = 10$	91
6.17	Wpływ $S_{\max}$ na $\bar{\epsilon}$ dla TS przy $M_m = 10$ i $M_p = 10$	92
6.18	Wpływ M_m na $\bar{\epsilon}$ dla TS przy $T_{\max} = 5$ i $M_p = 10$	93
6.19	Wpływ $\tilde{\mathcal{P}}$ na $\bar{\epsilon}$ dla HA przy $\tilde{\Lambda}_{\text{GA}} = 5\ 000$ i $\tilde{\Lambda}_{\text{BL}} = 15\ 000$ ($\beta_{\text{SA}} = \text{BM}$, $\Delta_{\max} = 0,01$)	94
6.20	Wpływ $\tilde{\mathcal{P}}$ na $\bar{\epsilon}$ dla HA przy $\tilde{\Lambda}_{\text{GA}} = 10\ 000$ i $\tilde{\Lambda}_{\text{BL}} = 10\ 000$ ($\beta_{\text{SA}} = \text{BM}$, $\Delta_{\max} = 0,01$)	95
6.21	Wpływ $\tilde{\mathcal{P}}$ na $\bar{\epsilon}$ dla HA przy $\tilde{\Lambda}_{\text{GA}} = 15\ 000$ i $\tilde{\Lambda}_{\text{BL}} = 5\ 000$ ($\beta_{\text{SA}} = \text{BM}$, $\Delta_{\max} = 0,01$)	95
6.22	Wpływ C na $\bar{\epsilon}$ dla HA przy $\tilde{\Lambda}_{\text{GA}} = 5\ 000$ i $\tilde{\Lambda}_{\text{BL}} = 15\ 000$ ($\beta_{\text{SA}} = \text{BM}$, $\Delta_{\max} = 0,01$)	96
6.23	Wpływ $\tilde{\Lambda}_{\text{GA}}$ i $\tilde{\Lambda}_{\text{SA}}$ na $\bar{\epsilon}$ dla HA przy $C=2$ ($\alpha_{\text{GA}} = \text{2PX}$, $\beta_{\text{SA}} = \text{BM}$, $\Delta_{\max} = 0,01$)	97
6.24	Wpływ $\tilde{\Lambda}_{\text{GA}}$ i $\tilde{\Lambda}_{\text{SA}}$ na $\bar{\epsilon}$ dla HA przy $C=1$ ($\alpha_{\text{GA}} = \text{2PX}$, $\beta_{\text{SA}} = \text{BM}$, $\Delta_{\max} = 0,01$)	98

6.25	Porównanie $\bar{\epsilon}$ w zależności od zaawansowania poszukiwań ($\tilde{\Lambda}$) wybranych metod dla grupy modeli o $\tilde{\Omega} \in \{10; 30; 60; 90\}$	101
6.26	Rozwiązania wybranych modeli o $\tilde{\Omega}=10$ i zróżnicowanych ograniczeniach zasobowych . .	107
6.27	Rozwiązania z rys. 6.26 dla punktu $(\mu_1, \dots, \mu_{\tilde{\Omega}})$ w przestrzeni sposobów wykonania zapewniającego optymalną wartość NPV	108
6.28	Liczebność punktów w przestrzeni parametrów w zależności od i_{NPV}	109

Spis tabel

2.1	Kierunki optymalizacji w modelach harmonogramowania projektów	16
2.2	Wybrane reguły priorytetu stosowane w rozwiązywaniu problemów harmonogramowania projektów	23
6.1	Mierniki oceny struktury sieci oraz ścisłości ograniczeń zasobowych.	75
6.2	Wielkości sąsiedztw w procesie poszukiwania dla $C = 5$, $S = 10$, $N = 30$ oraz $h = 0$. . .	79
6.3	Wpływ przekształcenia logarytmicznego i wykładniczego zmiennej $\bar{\epsilon}$ na wartości wybranych parametrów kształtu rozkładu	99
6.4	Średni błąd ($\bar{\epsilon}$) dla modeli o $\tilde{\Omega} = 10$ i $NC = 1,5$ po $\tilde{\Lambda} = 5\ 000$, $10\ 000$ i $20\ 000$ zbudowanych rozwiązań	102
6.5	Liczba odnalezionych rozwiązań optymalnych ($\tilde{\lambda}_{opt}$) dla modeli o $\tilde{\Omega} = 10$ i $NC = 1,5$ po $\tilde{\Lambda} = 5\ 000$, $10\ 000$ i $20\ 000$ zbudowanych rozwiązań	103
6.6	Podsumowanie wyników ANOVA zmiennej zależnej $\sqrt{\bar{\epsilon}}$ i zmiennych niezależnych $\tilde{\Omega}$, NC , $\bar{RS}^o$, $\bar{RS}^v$ dla wyników uzyskanych przez GA	104
6.7	Podsumowanie wyników ANOVA zmiennej zależnej $\sqrt{\bar{\epsilon}}$ i zmiennych niezależnych $\tilde{\Omega}$, NC , $\bar{RS}^o$, $\bar{RS}^v$ dla wyników uzyskanych przez SA	104
6.8	Podsumowanie wyników ANOVA zmiennej zależnej $\sqrt{\bar{\epsilon}}$ i zmiennych niezależnych $\tilde{\Omega}$, NC , $\bar{RS}^o$, $\bar{RS}^v$ dla wyników uzyskanych przez TS	105
6.9	Podsumowanie wyników ANOVA zmiennej zależnej $\sqrt{\bar{\epsilon}}$ i zmiennych niezależnych $\tilde{\Omega}$, NC , $\bar{RS}^o$, $\bar{RS}^v$ dla wyników uzyskanych przez HA	106
B.1	Identyfikatory elementów danych w formacie pso	117
C.1	Statystyki opisowe wyników algorytmu SA dla $\tilde{\Omega} = 30$	120
C.2	Statystyki opisowe wyników algorytmu GA dla $\tilde{\Omega} = 30$	126
C.3	Statystyki opisowe wyników algorytmu TS dla $\tilde{\Omega} = 30$	137
C.4	Statystyki opisowe wyników algorytmu HA dla $\tilde{\Omega} = 30$	140
C.5	Statystyki opisowe wyników wybranych metaheurystyk dla modeli z liczbą czynności $\tilde{\Omega} \in \{10; 30; 60; 90\}$	153
D.1	Podsumowanie wyników jednoczynnikowej analizy wariancji dla $\tilde{\mathcal{P}}$ i g_{max} w GA	156
D.2	Podsumowanie wyników wybranych testów <i>post-hoc</i> dla $\tilde{\mathcal{P}}$ i g_{max} w GA	157
D.3	Podsumowanie wyników jednoczynnikowej analizy wariancji dla α w GA	158
D.4	Podsumowanie wyników wybranych testów <i>post-hoc</i> dla α w GA	159
D.5	Podsumowanie wyników jednoczynnikowej analizy wariancji dla β w GA bez elityzmu . .	160
D.6	Podsumowanie wyników wybranych testów <i>post-hoc</i> dla β w GA bez elityzmu	161
D.7	Podsumowanie wyników jednoczynnikowej analizy wariancji dla β w GA z elityzmem . .	162
D.8	Podsumowanie wyników wybranych testów <i>post-hoc</i> dla β w GA z elityzmem	163
D.9	Podsumowanie wyników jednoczynnikowej analizy wariancji dla ζ w GA	164
D.10	Podsumowanie wyników wybranych testów <i>post-hoc</i> dla ζ w GA	164
D.11	Podsumowanie wyników jednoczynnikowej analizy wariancji dla p_α w GA	165
D.12	Podsumowanie wyników wybranych testów <i>post-hoc</i> dla p_α w GA	165
D.13	Podsumowanie wyników jednoczynnikowej analizy wariancji dla p_β w GA	166
D.14	Podsumowanie wyników wybranych testów <i>post-hoc</i> dla p_β w GA	167
D.15	Podsumowanie wyników jednoczynnikowej analizy wariancji dla elityzmu w GA	168

D.16 Podsumowanie wyników jednoczynnikowej analizy wariancji dla β w SA	170
D.17 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla β w SA	170
D.18 Podsumowanie wyników jednoczynnikowej analizy wariancji dla C w SA	171
D.19 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla C w SA	171
D.21 Podsumowanie wyników jednoczynnikowej analizy wariancji dla S w SA	172
D.22 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla S w SA	172
D.23 Podsumowanie wyników jednoczynnikowej analizy wariancji dla $p_m < 0,1$ w SA	173
D.24 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla $p_m < 0,1$ w SA	173
D.25 Podsumowanie wyników jednoczynnikowej analizy wariancji dla $p_m \geq 0,1$ w SA	174
D.26 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla $p_m \geq 0,1$ w SA	174
D.27 Podsumowanie wyników jednoczynnikowej analizy wariancji dla p_p w SA	175
D.28 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla p_p w SA	175
D.29 Podsumowanie wyników jednoczynnikowej analizy wariancji dla $\Delta_{\max}$ w SA	176
D.30 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla $\Delta_{\max}$ w SA	176
D.31 Podsumowanie wyników jednoczynnikowej analizy wariancji dla β w TS	177
D.32 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla β w TS	177
D.33 Podsumowanie wyników jednoczynnikowej analizy wariancji dla $S_{\max}$ w TS	178
D.34 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla $S_{\max}$ w TS	178
D.35 Podsumowanie wyników jednoczynnikowej analizy wariancji dla M_m w TS	179
D.36 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla M_m w TS	180
D.37 Podsumowanie wyników jednoczynnikowej analizy wariancji dla M_p w TS	181
D.38 Podsumowanie wyników jednoczynnikowej analizy wariancji dla $T_{\max}$ w TS	182
D.39 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla $T_{\max}$ w TS	182
D.40 Podsumowanie wyników jednoczynnikowej analizy wariancji dla $\tilde{\mathcal{P}}$ i $g_{\max}$ w HA	183
D.41 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla $\tilde{\mathcal{P}}$ i $g_{\max}$ w HA	184
D.42 Podsumowanie wyników jednoczynnikowej analizy wariancji dla $\tilde{GA}$ i $\tilde{SA}$ w HA	185
D.43 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla $\tilde{GA}$ i $\tilde{SA}$ w HA	187
D.44 Podsumowanie wyników jednoczynnikowej analizy wariancji dla C w HA	189
D.45 Podsumowanie wyników wybranych testów <i>post-hoc</i> dla C w HA	189
D.46 Podsumowanie wyników jednoczynnikowej analizy wariancji dla $\Delta_{\max}$ w HA	190
D.47 Podsumowanie wyników jednoczynnikowej analizy wariancji dla α w HA	191

Spis algorytmów

5.1	Szeregową procedurą budowy harmonogramu	55
5.2	Równoległą procedurą budowy harmonogramu	55
5.3	Procedurą budowy harmonogramu zgodną z postulatem przedstawionym w (Ulusoy i in., 2001)	56
5.4	Procedurą mutacji Boctora (BM)	57
5.5	Procedurą mutacji Hartmanna (HM)	57
5.6	Procedurą krzyżowania jednopunktowego (1PX)	59
5.7	Procedurą krzyżowania dwupunktowego (2PX)	59
5.8	Procedurą krzyżowania kolejnościowego (PSX)	59
5.9	Procedurą krzyżowania równomiernego (UX)	59
5.10	Ogólny schemat działania SA	60
5.11	Ogólny schemat działania TS	61
5.12	Ogólny schemat działania GA	62
5.13	Szczegółowy schemat działania GA	64
5.14	Procedurą losowania według koła ruletki	66
5.15	Procedurą selekcji turniejowej	66
5.16	Ogólny schemat działania SS	68
5.17	Ogólny schemat działania PLA	69

Bibliografia

- G. Y. Abbasi i Y. A. Arabiat. A Heuristic to Maximize the Net Present Value for Resource-Constrained Project-Scheduling Problems. *Project Management Journal*, 32(2):17–24, 2001.
- N. R. Achuthan i A. Hardjawidjaja. Project Scheduling under Time Dependent Costs. A Branch and Bound Algorithm. *Annals of Operations Research*, 108:55–74, 2001.
- M. K. Agrawal, S. E. Elmaghraby i W. S. Herroelen. DAGEN: A Generator of Testsets for Project Activity Nets. *European Journal of Operational Research*, 90:376–382, 1996.
- T. Ahn i S. S. Erenguc. The resource constrained project scheduling problem with multiple crashable modes: A heuristic procedure. *European Journal of Operational Research*, 107:250–259, 1998.
- J. Alcaraz i C. Maroto. A Robust Genetic Algorithm for Resource Allocation in Project Scheduling. *Annals of Operations Research*, 102:83–109, 2001.
- S. I. G. Allam. Multi-project scheduling: a new categorization for heuristic scheduling rules in construction scheduling problems. *Construction Management and Economics*, 6:93–115, 1988.
- S. Arisawa i E. Elmaghraby. Optimal time-cost trade-offs in GERT networks. *Management Science*, 18(11):589–599, 1972.
- R. S. Baar, B. L. Golden, J. P. Kelly, M. C. G. Resende i W. R. Stewart. Designing and Reporting on Computational Experiments with Heuristics Methods. *Proceedings of the International Conference on Metaheuristics for Optimization*, strony 1–17. Kluwer Publishing, 1995.
- T. Baar, P. Brucker i S. Kunst. Tabu-search algorithms and lower bounds for the resource-constrained project scheduling problem. S. Voss, S. Martello, I. Osman i C. Roucairol, red., *Meta-Heuristics: Advances and Trends in Local Search Paradigms for Optimization*, strony 1–18. Kluwer Academic, 1998.
- J. Bailey, H. Alfares i W. Y. Lin. Optimization and Heuristic Models to Integrate Project Task and Manpower Scheduling. *Computers & Industrial Engineering*, 29(1–4):473–476, 1995.
- K. R. Baker. *Introduction to Sequencing and Scheduling*. Wiley, New York, 1974.
- P. V. Balakrishnan i V. S. Jacob. Genetic Algorithms for Product Design. *Management Science*, 42:1105–1117, 1996.
- P. Baptiste i C. Le Pape. Constraint Propagation and Decomposition Techniques for Highly Disjunctive and Highly Cumulative Project Scheduling Problems. *Constraints: an International Journal*, 5:119–139, 2000.
- P. Baptiste, C. Le Pape i W. Nuijten. Satisfiability tests and time-bound adjustments for cumulative scheduling problems. *Annals of Operations Research*, 92:305–333, 1999.
- D. Barbucha, M. Forkiewicz, P. Jedrzejowicz i E. Ratajczak. Population Learning Algorithm Versus Evolutionary Computation. *Proceedings of the 15th International Parallel & Distributed Processing Symposium (IPDPS-01)*, strony 131–131, Los Alamitos, CA, 2001. IEEE Computer Society.
- S. M. Baroum i J. H. Patterson. The development of cash flow weight procedures for maximizing the net present value of a project. *Journal of Operations Management*, 14(3):209–227, 1996.
- M. Bartusch, R. H. Möhring i F. J. Radermacher. Scheduling project networks with resource constraints and time windows. *Annals of Operations Research*, 16(1–4):201–240, 1988.
- N. Baskar, R. Saravanan, P. Asokan i G. Prabhakaran. Ants colony algorithm approach for multi-objective optimisation of surface grinding operations. *The International Journal of Advanced Manufacturing Technology*, 23(5–6):311–317, 2004.
- R. Battiti i G. Tecchiolli. The reactive tabu search. *ORSA Journal on Computing*, 6(2):126–140, 1994.
- J. C. Bean. Genetics and Random Keys for Sequencing and Optimization. *ORSA Journal on Computing*, 6:154–160, 1994.
- R. P. Beausoleil. Multiple Criteria Scatter Search. *MIC 2001 4th Metaheuristics International Conference*, strony 539–543, Porto, Portugal, 2001.
- L. Bednarski. *Analiza finansowa w przedsiębiorstwie*. Polskie Wydawnictwo Ekonomiczne, Warszawa, 1994.

- W. W. Bein, J. E. Kamburowski i M. F. M. Stallmann. Optimal reduction of two-terminal directed acyclic graphs. *SIAM Journal on Computing*, 21:1112–1129, 1992.
- E. B. Berman. Resource allocation in a PERT network under continuous activity time-cost functions. *Management Science*, 10(4):734–745, 1964.
- L. Bianco, P. Dell’Olmo i M. Grazia Speranza. Heuristics for multimode scheduling problems with dedicated resources. *European Journal of Operational Research*, 107:260–271, 1998.
- C. Bierwirth i D. C. Mattfeld. Production Scheduling and Rescheduling with Genetic Algorithms. *Evolutionary Computation*, 7(1):1–17, 1999.
- C. Bierwirth, D. C. Mattfeld i H. Kopfer. On Permutation Representations for Scheduling Problems. H. M. Voigt, W. Ebeling, I. Rechenberg i H. P. Schwefel, red., *Parallel Problem Solving from Nature IV*, strony 310–318. Springer–Verlag, 1996.
- C. Blum i A. Roli. Metaheuristics in Combinatorial Optimization: Overview and Conceptual Comparison. Raport instytutowy TR/IRIDIA/2001-13, Université Libre de Bruxelles, 2001.
- F. F. Bector. Some efficient multi-heuristic procedures for resource-constrained project scheduling. *European Journal of Operational Research*, 49(1):3–13, 1990.
- F. F. Bector. Heuristics for scheduling projects with resource restrictions and several resource-duration modes. *International Journal of Production Research*, 31(11):2547–2558, 1993.
- F. F. Bector. A new and efficient heuristic for scheduling projects with resource restrictions and multiple execution modes. *European Journal of Operational Research*, 90:349–361, 1996a.
- F. F. Bector. Resource-constrained project scheduling by simulated annealing. *International Journal of Production Research*, 34(8):2335–2351, 1996b.
- E. Bonabeau, M. Dorigo i G. Theraulaz. Inspiration for optimization from social insect behaviour. *Nature*, 406:39–42, 2000.
- J. Bos. Zoning in Forest Management: a Quadratic Assignment Problem Solved by Simulated Annealing. *Journal of Environmental Management*, 37(2):127–145, 1993.
- J. Böttcher, A. Drexler, R. Kolisch i F. Salewski. Project Scheduling Under Partially Renewable Resource Constraints. *Management Science*, 45(4):543–559, 1999. Również: Manuskrypty z Instytutu dla Betriebswirtschaftslehre der Universität Kiel, No. 398, July 1996.
- K. Bouleimen i H. Lecocq. A new efficient simulated annealing algorithm for the resource-constrained project scheduling problem. G. Barbarosoğlu, S. Karabatı, L. Özdamar i G. Ulusoy, red., *Proceedings of the Sixth International Workshop on Project Management and Scheduling*, strony 19–22, Istanbul, 1998. Boğaziçi University Printing Office.
- K. Bouleimen i H. Lecocq. Multi-objective simulated annealing for the resource-constrained multi-project scheduling problem. *Proceedings of the 7th International Workshop on Project Management and Scheduling*, Osnabrück, Germany, 2000.
- K. Bouleimen i H. Lecocq. A new efficient simulated annealing algorithm for the resource-constrained project scheduling problem and its multiple mode version. *European Journal of Operational Research*, 149:268–281, 2003.
- E. H. Bowman. The schedule-sequencing problem. *Operations Research*, 7(5):621–624, 1959.
- M. F. Bramlette i R. Cusic. A comparative evaluation of search methods applied to parametric design of aircraft. *Proceedings of the Third International Conference on Genetic Algorithms*, strony 213–218, San Francisco, CA, USA, 1989. Morgan Kaufmann Publishers.
- J. Brilman. *Nowoczesne koncepcje i metody zarządzania*. Polskie Wydawnictwo Ekonomiczne, Warszawa, 2002.
- British Standards. *Project management. Vocabulary*. Nr BS 6079-2:2000. BSI, 2000.
- British Standards. *Guide to Project Management*. Nr BS 6079-1:2002. BSI, 2002.
- M. B. Brown i A. B. Forsythe. Robust tests for the equality of variances. *Journal of the American Statistical Association*, 69:364–367, 1974.
- P. Brucker. *Scheduling Algorithms*. Springer–Verlag, Berlin, 1995.
- P. Brucker. Scheduling and constraint propagation. *Discrete Applied Mathematics*, 123:227–256, 2002.
- P. Brucker, A. Drexler, R. Möhring, K. Neumann i E. Pesch. Resource-constrained project scheduling: Notation, classification, models, and methods. *European Journal of Operational Research*, 112:3–41, 1999.
- P. Brucker, S. Knust, A. Schoo i O. Thiele. A branch and bound algorithm for the resource-constrained project scheduling problem. *European Journal of Operational Research*, 107:272–288, 1998.
- B. Bullnheimer, R. F. Hartl i C. Strauss. A new rank-based version of the Ant System: A computational study. *Central European Journal for Operations Research and Economics*, 7(1):25–38, 1999.

- J. Błażewicz. *Problemy optymalizacji kombinatorycznej: złożoność obliczeniowa, algorytmy aproksymacyjne*. Polskie Wydawnictwo Naukowe, Warszawa, 1986.
- J. Błażewicz, W. Cellary, R. Słowiński i J. Węglarz. *Algorytmy sterowania rozdziałem zadań i zasobów w kompleksie operacji*. Wydawnictwo Politechniki Poznańskiej, Poznań, 1979.
- V. Campos, M. Laguna i R. Martí. Context-Independent Scatter and Tabu Search for Permutation Problems, 2003. Ukaże się w *INFORMS Journal on Computing*.
- J. Carlier i E. Pinson. An algorithm for solving the job-shop problem. *Management Science*, 35(2):164–176, 1989.
- C. Cavalcante, V. Cavalcante, C. Ribeiro i C. de Souza. Parallel cooperative approaches for the labor constrained scheduling problem. Preprint 2000.28, Instituto de Computação Universidade Estadual de Campinas, Brasil, 2000.
- C. C. Barros Cavalcante i C. Carvalho de Souza. A Tabu Search Approach for Scheduling Problem Under Labour Constraints. Relatório Técnico IC-97-13, Instituto de Computação Universidade Estadual de Campinas, Brasil, 1997.
- A. Cesta, A. Oddi i S. F. Smith. A Constraint-Based Method for Project Scheduling with Time Windows. *Journal of Heuristics*, 8:109–136, 2002.
- M. Chelaka, L. Abeyasinghe, D. J. Greenwood i D. E. Johansen. An efficient method for scheduling construction projects with resource constraints. *International Journal of Project Management*, 19:29–45, 2001.
- M. Y. Chen, K. K. Chen, H. K. Chiang, H. S. Huang i M. J. Huang. Comparing extended classifier system and genetic programming for financial forecasting: an empirical study. *Soft Computing*, 11(12):1173–1183, 2007.
- S. H. Chen. *Algorithms and Genetic Programming in Computational Finance*. Kluwer, Boston, 2002.
- R. Cheng i M. Gen. Performance evaluation of genetic algorithms for flowshop scheduling problems. *Proceedings of the First IEEE Conference on Evolutionary Computation*, strony 736–741, Orlando, Florida, 1994.
- R. Cheng, G. Mitsuo i Y. Tsujimura. A tutorial survey of job-shop scheduling problems using genetic algorithms. Representation. *Computers & Industrial Engineering*, 30(4):983–997, 1996.
- J. H. Cho i Y. D. Kim. A Simulated Annealing Algorithm for Resource Constrained Project Scheduling Problems. *Journal of Operational Research Society*, 48(7):736–744, 1997.
- A. Colorni, M. Dorigo, M. Maffioli, V. Maniezzo, G. Righini i M. Trubian. Heuristics from Nature for Hard Combinatorial Optimization Problems. *International Transactions in Operational Research*, 3(1):1–21, 1996.
- R. W. Conway, W. L. Maxwell i W. L. Miller. *Theory of Scheduling*. Addison-Wesley, MA, 1967.
- D. F. Cooper. Heuristics for scheduling resource-constrained projects: An experimental investigation. *Management Science*, 22(11):1186–1194, 1976.
- T. G. Crainic, M. Toulouse i M. Gendreau. Toward a Taxonomy of Parallel Tabu Search Heuristics. *INFORMS Journal on Computing*, 9(1):61–72, 1997.
- W. B. Crowston. Models for Project Management. *Sloan Management Review*, (spring):25–42, 1971.
- M. Dacorogna, O. Pictet, B. Chopard, R. Schirru i M. Tomassini. Using genetic algorithms for robust optimization in financial applications. *Neural Network World*, (5):573–587, 1995.
- E. W. Davis. *An Exact Algorithm for the Multiple Constrained-Resource Project Scheduling Problem*. Praca doktorska, Yale University, 1969.
- E. W. Davis. An experimental investigation of resource allocation in multiactivity projects. *Operational Research Quarterly*, 24:587–591, 1973.
- E. W. Davis. Project network summary measures and constrained resource scheduling. *IIE Transactions*, 7:132–142, 1975.
- E. W. Davis i G. E. Heidorn. An Algorithm for Optimal Project Scheduling under Multiple Resource Constraints. *Management Science*, 17(12):803–816, 1971.
- E. W. Davis i J. H. Patterson. A Comparison of Heuristic and Optimal Solutions in Resource-Constrained Project Scheduling. *Management Science*, 21(8):944–955, 1975.
- L. Davis. Applying Adaptive Algorithms to Epistatic Domains. *Proceedings of the 1st International Conference on Genetic Algorithms and their Applications*, strony 162–164, Los Angeles, California, 1985a.
- L. Davis. Job Shop Scheduling with Genetic Algorithms. J. J. Grefenstette, red., *Proceedings of the 9th International Joint Conference on Artificial Intelligence*, strony 136–140, Pittsburgh, Pennsylvania, 1985b. Lawrence Erlbaum Associates.
- N. Dayanand i R. Padman. Project contracts and payment schedules: the client's problem. *Management Science*, 47(12):1654–1667, 2001a.
- N. Dayanand i R. Padman. A Two Stage Search Heuristic for Scheduling Payments in Projects. *Annals of Operations Research*, 102:197–220, 2001b.

- S. Van de Vonder, F. Ballestin, E. Demeulemeester i W. Herroelen. Heuristic procedures for reactive project scheduling. *Computers & Industrial Engineering*, 52(1):11–28, 2007.
- D. Debels i M. Vanhoucke. A Bi-Population Based Genetic Algorithm for the Resource-Constrained Project Scheduling Problem. *Lecture Notes in Computer Science*, 3483:378–387, 2005.
- R. F. Deckro, J. E. Hebert, W. A. Verdini, P. H. Grimsrud i S. Venkateshwar. Nonlinear Time/Cost Tradeoff Models in Project Management. *Computers & Industrial Engineering*, 28(2):219–229, 1995.
- E. Demeulemeester, B. de Reyck i W. Herroelen. The discrete time/resource trade-off problem in project networks: a branch-and-bound approach. *IIE Transactions*, 32:1059–1069, 2000.
- E. Demeulemeester i W. Herroelen. A Branch-And-Bound Procedure for the Multiple Resource-Constrained Project Scheduling. *Management Science*, 38(12):1803–1818, 1992.
- E. Demeulemeester, M. Vanhoucke i W. Herroelen. RanGen: A Random Network Generator for Activity-On-The-Node Networks. *Journal of Scheduling*, 6:17–38, 2003.
- E. L. Demeulemeester i W. S. Herroelen. An efficient optimal solution procedure for the preemptive resource-constrained project scheduling problem. *European Journal of Operational Research*, 90:334–348, 1996.
- E. L. Demeulemeester i W. S. Herroelen. New Benchmark Results for the Resource-Constrained Project Scheduling Problem. *Management Science*, 43(11):1485–1492, 1997.
- G. W. DePuy i G. E. Whitehouse. A simple and effective heuristic for the resource constrained project scheduling problem. *International Journal of Production Research*, 39(14):3275–3287, 2001.
- M. Dixon, red. *Project Management. Body of Knowledge*. Association for Project Management, 4 edycja, 2000.
- B. Dodin i A. A. Elimam. Integrated project scheduling and material planning with variable activity duration and rewards. *IIE Transactions*, 33:1005–1018, 2001.
- B. Dodin, A. A. Elimam i E. Rolland. Tabu search in audit scheduling. *European Journal of Operational Research*, 106:373–392, 1998.
- R. H. Doersch i J. H. Patterson. Scheduling a project to maximize its present value: a zero-one programming approach. *Management Science*, 23(8):882–889, 1977.
- M. Dorigo, G. DiCaro i L. M. Gambardella. Ant Algorithms for Discrete Optimization. *Artificial Life*, 5(3):137–172, 1999.
- M. Dorigo, V. Maniezzo i A. Colorni. The Ant System: Optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man, and Cybernetics. Part B*, 26(1):29–41, 1996.
- M. Dorigo i T. Stützle. The Ant Colony Optimization Metaheuristic: Algorithms, Applications and Advances. F. Glover i G. Kochenberger, red., *Handbook of Metaheuristics*, wol. 57 serii *International Series in Operations Research & Management Science*, strony 251–285. Kluwer Academic Publishers, Norwell, MA, 2002.
- C. Dorndorf, E. Pesch i T. Phan-Huy. A branch-and-bound algorithm for the resource-constrained project scheduling problem. *Mathematical Methods of Operations Research*, 52:413–439, 2000a.
- U. Dorndorf i E. Pesch. Evolution based learning in a job shop scheduling environment. *Computers & Operations Research*, 22(1):25–40, 1995.
- U. Dorndorf, E. Pesch i T. Phan-Huy. A Time-Oriented Branch-and-Bound Algorithm for Resource-Constrained Project Scheduling with Generalised Precedence Constraints. *Management Science*, 46(10):1365–1384, 2000b.
- U. Dorndorf, T. Phan-Huy i E. Pesch. A survey of interval capacity consistency tests for time- and resource constrained scheduling. J. Węglarz, red., *Project Scheduling: Recent Models, Algorithms and Applications*, rozdział 10, strony 333–353. Kluwer Academic Publishers, 1998.
- A. Drexler. Scheduling of project networks by job assignment. *Management Science*, 37(12):1590–1602, 1991.
- A. Drexler i J. Grünewald. Nonpreemptive multi-mode resource-constrained project scheduling. *IIE Transactions*, 25(5):74–81, 1993.
- A. Drexler, R. Nissen, J. H. Patterson i F. Salewski. ProGen/ πx – An instance generator for resource-constrained project scheduling problems with partially renewable resources and further extensions. *European Journal of Operational Research*, 125:59–72, 2000.
- E. I. Ducheyne, R. R. De Wulfand i B. De Baets. Single versus multiple objective genetic algorithms for solving the even-flow forest management problem. *Forest Ecology and Management*, 201(2–3):259–273, 2004.
- S. E. Elmaghraby. The theory of networks and management science. Part I. *Management Science*, 17(1):9–34, 1970a.
- S. E. Elmaghraby. The theory of networks and management science. Part II. *Management Science*, 17(2):B54–B71, 1970b.
- S. E. Elmaghraby i J. Kamburowski. The analysis of activity networks under generalized precedence relations (GPRs). *Management Science*, 38(9):1245–1263, 1992.

- E. A. Elsayed. Algorithms for project scheduling with resource constraints. *International Journal of Production Research*, 21(1):95–103, 1982.
- E. A. Elsayed i N. Z. Nasr. Heuristics for resource-constrained scheduling. *International Journal of Production Research*, 24(2):299–310, 1986.
- R. Etgar i A. Shtub. Scheduling project activities to maximize the net present value – the case of linear time-dependent cash flows. *International Journal of Production Research*, 37(2):329–339, 1999.
- E. Falkenauer i S. Bouffouix. A Genetic Algorithm for Job Shop. *Proceedings of the 1991 IEEE International Conference on Robotics and Automation*, strony 824–829, Sacramento, California, 1991.
- A. Fest, R. H. Möhring, F. Stork i M. Uetz. Resource-Constrained Project Scheduling with Time Windows: A Branching Scheme Based On Dynamic Release Dates. Raport instytutowy 596/1998, Technische Universität Berlin, 1999. wersja poprawiona.
- B. Franck, K. Neumann i C. Schwindt. Truncated branch-and-bound, schedule-construction, and schedule-improvement procedures for resource-constrained project scheduling. *OR Spektrum*, 23:297–324, 2001.
- D. R. Fulkerson. A network flow computation for project cost curves. *Management Science*, 7(2):167–178, 1961.
- P. A. Games i J. F. Howell. Pairwise Multiple Comparison Procedures with Unequal N's and/or Variances: A Monte Carlo Study. *Journal of Educational Statistics*, 1:113–125, 1976.
- F. García-López, B. Melián, J. A. Moreno-Pérez i J. M. Moreno-Vega. Parallelization of the Scatter Search. *Parallel Computing*, 29:575–589, 2003.
- D. D. Gemmill i Y. W. Tsai. Using a simulated annealing algorithm to schedule activities of resource-constrained projects. *Project Management Journal*, 28(4):8–20, 1997.
- F. Glover. A Multiphase Dual Algorithm for the Zero-One Integer Programming Problem. *Operations Research*, 13(6):879, 1965.
- F. Glover. Future paths for integer programming and links to artificial intelligence. *Computers & Operations Research*, 13:533–549, 1986.
- F. Glover. Tabu Search – Part I. *ORSA Journal on Computing*, 1(3):190–206, 1989.
- F. Glover. Tabu Search – Part II. *ORSA Journal on Computing*, 2(1):4–32, 1990a.
- F. Glover. Tabu Search: Tutorial. *Interfaces*, 20(4):74–94, 1990b.
- F. Glover. Scatter Search and Path Relinking. Working Paper HCES-01-99, Hearin Center for Enterprise Science, University of Mississippi, 1999.
- F. Glover. Tutorial on Surrogate Constraint Approaches for Optimization in Graphs. *Journal of Heuristics*, 9(3): 175–227, 2003.
- F. Glover i M. Laguna. *Tabu search*. Kluwer Academic Publishers, 1997.
- F. Glover i M. Laguna. Tabu Search. P. M. Pardalos i M. G. C. Resende, red., *Handbook of Applied Optimization*, strony 194–208. Oxford University Press, 2002.
- F. Glover, M. Laguna i R. Martí. Fundamentals of Scatter Search and Path Relinking. *Control & Cybernetics*, 39 (3):653–684, 2000. również jako HCES-06-00, Hearin Center for Enterprise Science, University of Mississippi.
- F. Glover, M. Laguna i R. Martí. New Ideas and Applications of Scatter Search and Path Relinking. Raport instytutowy HCES-07-02, Hearin Center for Enterprise Science, University of Mississippi, 2002a.
- F. Glover, M. Laguna i R. Martí. Scatter Search and Path Relinking: Advances and Applications. Raport instytutowy HCES-03-02, Hearin Center for Enterprise Science, University of Mississippi, 2002b.
- F. Glover, M. Laguna i R. Martí. *Scatter Search*. Springer-Verlag, 2003a. w druku.
- F. Glover, M. Laguna i R. Martí. Scatter Search and Path Relinking: Foundations and Advanced Designs, 2003b. Ukaze się w *New Optimization Techniques in Engineering*, G. Onwubolu (red.), Springer-Verlag.
- D. E. Goldberg i R. Lingle. Alleles, Loci and the Traveling Salesman Problem. *Proceedings of the First International Conference on Genetic Algorithms and their Applications*, strony 154–159, Hillsdale, New Jersey, 1985.
- R. L. Graham, E. L. Lawler, J. K. Lenstra i A. H. G. Rinnooy Kan. Optimization and approximation in deterministic sequencing and scheduling theory: A survey. *Annals of Discrete Mathematics*, 5:287–326, 1979.
- R. C. Grinold. The payment scheduling problem. *Naval Research Logistics Quarterly*, 9:123–136, 1972.
- S. K. Gupta, J. Kyriaris i C. M. Ip. Project selection and sequencing to maximize net present value of the total return. *Management Science*, 38(5):751–752, 1992.
- W. J. Gutjahr, C. Strauss i E. Wagner. A Stochastic Branch-and-Bound Approach to Activity Crashing in Project Management. *Journal on Computing*, 12(2):125–135, 2000.
- E. W. Hans, W. Herroelen, R. Leus i G. Wullink. A hierarchical approach to multi-project planning under uncertainty. *Omega*, 35(5):563–577, 2007.

- P. Hansen. The steepest ascent mildest descent heuristic for combinatorial programming. *Congress on Numerical Methods in Combinatorial Optimization*, Capri, Italy, 1986.
- M. Hapke, A. Jaskiewicz i R. Słowiński. Interactive analysis of multiple-criteria project scheduling problems. *European Journal of Operational Research*, 107:315–324, 1998.
- S. Hartmann. A Competitive Genetic Algorithm for Resource-Constrained Project Scheduling. Manuscripte 451, Institut für Betriebswirtschaftslehre der Universität Kiel, 1997.
- S. Hartmann. Project Scheduling with Multiple Modes: A Genetic Algorithm. *Annals of Operations Research*, 102: 111–135, 2001. Również: Manuskrypty z Instytutu dla Betriebswirtschaftslehre der Universität Kiel, No. 435, March 1997.
- S. Hartmann. A Self-Adapting Genetic Algorithm for Project Scheduling under Resource Constraints. *Naval Research Logistics*, 49:433–448, 2002.
- S. Hartmann i A. Drexl. Project Scheduling with Multiple Modes: A Comparison of Exact Algorithms. Manuscripte 430, Institut für Betriebswirtschaftslehre der Universität Kiel, 1997.
- S. Hartmann i R. Kolisch. Experimental evaluation of state-of-the-art heuristics for the resource-constrained project scheduling problem. *European Journal of Operational Research*, 127:394–407, 2000. Również: Manuskrypty z Instytutu dla Betriebswirtschaftslehre der Universität Kiel, No. 476, September 1998.
- R. Heilmann. Resource-constrained project scheduling: a heuristic for the multi-mode case. *OR Spektrum*, 23: 335–357, 2001.
- R. Heilmann. A branch-and-bound procedure for the multi-mode resource-constrained project scheduling problem with minimum and maximum time lags. *European Journal of Operational Research*, 144:348–365, 2003.
- W. Herroelen. Project Scheduling. Theory and Practice. *Production and Operations Management*, 14(4):413–432, 2005.
- W. Herroelen, E. Demeulemeester i B. De Reyck. A note on the paper "Resource-constrained project scheduling: Notation, classification, models and methods" by Brucker et al. *European Journal of Operational Research*, 128: 679–688, 2001.
- W. Herroelen, B. De Reyck i E. Demeulemeester. Resource-constrained project scheduling: a survey of recent developments. *Computers & Operations Research*, 25(4):279–302, 1998.
- W. S. Herroelen, P. Van Dommelen i E. L. Demeulemeester. Project networks models with discounted cash flows a guided tour through recent developments. *European Journal of Operational Research*, 100:97–121, 1997.
- W. S. Herroelen i B. De Reyck. Phase transitions in project scheduling. *Journal of Operational Research Society*, 50:148–156, 1999.
- A. Hertz, É. D. Taillard i D. de Werra. Tabu Search. E. Aarts i J. K. Lenstra, red., *Local search in combinatorial optimization*, strony 121–136. John Wiley & Sons Ltd., 1997.
- K. S. Hindi, H. Yang i K. Fleszar. An evolutionary algorithm for resource-constrained project scheduling. *IEEE Transactions on Evolutionary Computation*, 6(5):512–518, 2002.
- Y. Hochberg i A. Tamhane. *Multiple comparison procedures*. Wiley, New York, 1987.
- J. H. Holland. *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor, 1975.
- M. Hougham, red. *Syllabus for the APMP Examination*. Association for Project Management, 2000.
- T. H. Hsiung i S. Olejnik. Contrast analysis for additive nonorthogonal two-factor designs in unequal variance cases. *British Journal of Mathematical and Statistical Psychology*, 47:337–354, 1994.
- O. Icmeli i S. S. Erenguc. A branch and bound procedure for the resource constrained project scheduling problem with discounted cash flows. *Management Science*, 42(10):1395–1408, 1996a.
- O. Icmeli i S. S. Erenguc. The resource constrained time/cost tradeoff projects with discounted cash flows. *Journal of Operations Management*, 14(3):255–275, 1996b.
- O. Icmeli, S. S. Erenguc i C. J. Zappe. Project Scheduling Problems: A Survey. *International Journal of Operations & Production Management*, 13(11):80–91, 1993.
- O. Icmeli i W. O. Rom. Solving the resource constrained project scheduling problem with optimization subroutine library. *Computers & Operations Research*, 23(8):801–817, 1996.
- O. Icmeli-Tukel i W. O. Rom. Ensuring quality in resource constrained project scheduling. *European Journal of Operational Research*, 103:483–496, 1997.
- L. R. Ireland. Managing Multiple Projects in 21st Century. Patrz Pennypacker i Dye (2002), rozdział 3, strony 21–34.
- A. Jain i S. Meeran. A Multi-Level Hybrid Framework for the Deterministic Job-Shop Scheduling Problem. Department of Applied Physics, Electronic and Mechanical Engineering, University of Dundee, Dundee, Scotland, 1998a.

- A. Jain i S. Meeran. A Multi-Level Hybrid Framework for the General Flow-Shop Scheduling Problem. Department of Applied Physics, Electronic and Mechanical Engineering, University of Dundee, Dundee, Scotland, 1998b.
- K. Jajuga i T. Jajuga. *Inwestycje: instrumenty finansowe, aktywa niefinansowe, ryzyko finansowe, inżynieria finansowa*. Wydawnictwo Naukowe PWN, Warszawa, 2006.
- A. Janiak. *Wybrane problemy i algorytmy szeregowania zadań i rozdziału zasobów*. Akademicka Oficyna Wydawnicza PLJ, Warszawa, 1999.
- A. Jaskiewicz. *Multiple objective metaheuristic algorithms for combinatorial optimization*. Rozprawa habilitacyjna, Poznan University of Technology, Poznań, 2001.
- J. Jędrzejowicz i P. Jędrzejowicz. PLA-Based Permutation Scheduling. *Foundations of Computing and Decision Sciences*, 28(3), 2003.
- P. Jędrzejowicz. Social Learning Algorithm as a Tool for solving Some Difficult Scheduling Problems. *Foundations of Computing and Decision Sciences*, 24(2):51–66, 1999.
- P. Jędrzejowicz i E. Ratajczak. Population Learning for Resource-Constrained Project Scheduling, 2003.
- J. Józefowska, M. Mika, R. Różycki, G. Waligóra i J. Węglarz. Solving the discrete-continuous project scheduling problem via its discretization. *Mathematical Methods of Operations Research*, 52:489–499, 2000.
- J. Józefowska, M. Mika, R. Różycki, G. Waligóra i J. Węglarz. Simulated Annealing for Multi-Mode Resource-Constrained Project Scheduling. *Annals of Operations Research*, 102:137–155, 2001.
- M. Kaboudan. Biologically Inspired Algorithms for Financial Modelling. *Genetic Programming And Evolvable Machines*, 7(3):285–286, 2006.
- R. A. Kaimann. Coefficient of Network Complexity. *Management Science*, 21(2):172–177, 1974.
- R. A. Kaimann. Coefficient of Network Complexity: Erratum. *Management Science*, 21:1211–1212, 1975.
- J. Kamburowski, D. J. Michael i M. Stallmann. Optimal construction of project activity networks. *Proceedings of the 1992 Annual Meeting of the Decision Sciences Institute*, strony 1424–1426, San Francisco, CA, 1992.
- S. Karshenas i D. Haber. Economic optimization of construction project scheduling. *Construction Management and Economics*, 8:135–146, 1990.
- J. Katzel. Benefits and pitfalls of software for project management. *Plant Engineering*, strony 54–60, 1999.
- J. E. Kelly. The critical path method: Resources planning and scheduling. J. F. Muth i G. L. Thompson, red., *Industrial Scheduling*, rozdział 21, strony 347–365. Prentice-Hall, New Jersey, 1963.
- J. Kennedy i R. C. Eberhart. Particle swarm optimization. *Proceedings IEEE International Conference on Neural Networks (Perth, Australia)*, wol. IV, strony 1942–1948, Piscataway, NJ, 1995. IEEE Service Center.
- H. Kerzner. *Project Management. A Systems Approach to Planning, Scheduling, and Controlling*. John Wiley & Sons Ltd., 7 edycja, 2001.
- M. M. Khattab i F. Choobineh. A new approach for project scheduling with a limited resource. *International Journal of Production Research*, 29(1):185–198, 1991.
- K.-J. Kim i I. Hanb. Application of a hybrid genetic algorithm and neural network approach in activity-based costing. *Expert Systems with Applications*, 24(1):73–77, 2003.
- A. Kimms. A Genetic Algorithm for Multi-Level, Multi-Machine Lot Sizing and Scheduling. Manuscripte 415, Institut für Betriebswirtschaftslehre der Universität Kiel, 1996.
- A. Kimms. Maximizing the Net Present Value of a Project Under Resource Constraints Using a Lagrangian Relaxation Based Heuristic with Tight Upper Bounds. *Annals of Operations Research*, 102:221–236, 2001.
- R. E. Kirk. Effect magnitude: A different focus. *Journal of Statistical Planning and Inference*, 137:1634–1646, 2007.
- S. Kirkpatrick, C. D. Gelatt i M. P. Vecchi. Optimization by simulated annealing. *Science*, 220:671–680, 1983.
- R. Klein. Project scheduling with time-varying resource constraints. *International Journal of Production Research*, 38(16):3937–3952, 2000.
- R. Klein i A. Scholl. Scattered branch and bound. An adaptive search strategy applied to resource constrained project scheduling. *Central European Journal of Operations Research*, 7(3):177–201, 1999.
- A. J. Klockars i G. R. Hancock and M. J. McAweeney. Power of unweighted and weighted versions of simultaneous and sequential multiple-comparison procedures. *Psychological Bulletin*, 118(2):300–307, 1995.
- S. Kobayashi, I. Ono i M. Yamamura. An Efficient Genetic Algorithm for Job Shop Scheduling Problems. L. Eshelman, red., *Proceedings of the Sixth International Conference on Genetic Algorithms*, strony 506–511, San Francisco, California, 1995. Morgan Kaufmann.
- U. Kohlmorgen, H. Schmeck i K. Haase. Experiences with Fine-Grained Parallel Genetic Algorithms. Working paper, Institut für Angewandte Informatik und Formale Beschreibungsverfahren, Universität Karlsruhe, Germany, 1996.

- R. Kolisch. Efficient priority rules for the resource-constrained project scheduling problem. *Journal of Operations Management*, 14(3):179–192, 1996a.
- R. Kolisch. Serial and parallel resource-constrained project scheduling methods revisited: Theory and computation. *European Journal of Operational Research*, 90:320–333, 1996b.
- R. Kolisch. Resource allocation capabilities of commercial project management software packages. *Interfaces*, 29(4):19–31, 1999.
- R. Kolisch i A. Drexel. Adaptive search for solving project scheduling problems. *Naval Research Logistics*, 43: 23–40, 1996.
- R. Kolisch i A. Drexel. Local search for nonpreemptive multi-mode resource-constrained project scheduling. *IIE Transactions*, 29:987–999, 1997.
- R. Kolisch i S. Hartmann. Heuristic Algorithms for Solving the Resource Constrained Project Scheduling Problem: Classification and Computational Analysis. J. Węglarz, red., *Handbook on Recent Advances in Project Scheduling*, strony 147–178. Kluwer, 1999.
- R. Kolisch i R. Padman. An integrated survey of deterministic project scheduling. *Omega*, 29:249–272, 2001.
- R. Kolisch, C. Schwindt i A. Sprecher. Benchmark Instances for Project Scheduling Problems. J. Węglarz, red., *Handbook on Recent Advances in Project Scheduling*, strony 197–212. Kluwer, 1999.
- R. Kolisch i A. Sprecher. PSPLIB – A project scheduling problem library. *European Journal of Operational Research*, 96:205–216, 1996. Również: Manuskrypty z Instytutu dla Betriebswirtschaftslehre der Universität Kiel, No. 396, March 1996.
- R. Kolisch, A. Sprecher i A. Drexel. Characterization and Generation of a General Class of Resource-Constrained Project Scheduling Problems. Manuscript 301, Instytut dla Betriebswirtschaftslehre der Universität Kiel, 1992.
- R. Kolisch, A. Sprecher i A. Drexel. Characterization and Generation of a General Class of Resource-Constrained Project Scheduling Problems. *Management Science*, 41(10):1693–1703, 1995.
- A. Kostrubiec. Fitness Scaling in Evolutionary Algorithm for Production Scheduling. *Computer Integrated Manufacturing - Proceedings of the International Conference CIM 2001*, vol. 1, strony 277–284, Zakopane, 2001a.
- A. Kostrubiec. Operatory krzyżowania dla reprezentacji permutacyjnej algorytmu ewolucyjnego. L. Zawadzka, red., *Ilościowe i jakościowe aspekty zarządzania*, rozdział 3, strony 40–51. Wydawnictwo Politechniki Gdańskiej, Gdańsk, 2001b.
- J. R. Koza. A genetic approach to econometric modeling. P. Bourguine i B. Walliser, red., *Economics and Cognitive Science*, strony 57–75. Pergamon Press, Oxford, UK, 1991.
- C. Kramer. Extension of multiple range test to group means with unequal number of replications. *Biometrics*, 12: 307–310, 1956.
- A. G. Krishna i K. M. Rao. Multi-objective optimisation of surface grinding operations using scatter search approach. *The International Journal of Advanced Manufacturing Technology*, 29(5):475–480, 2005.
- J. D. Kromerey i M. A. La Rocca. Power and type I error rates of new pairwise multiple comparison procedures under heterogeneous variances. *Journal of Experimental Education*, 63(4):343–362, 1995.
- W. H. Kruskal i W. A. Wallis. Use of ranks in one-criterion variance analysis. *Journal of the American Statistical Association*, 47(260):583–621, 1952.
- I. Kurtulus i E. W. Davis. Multi-Project Scheduling: Categorization of Heuristic Rules Performance. *Management Science*, 28(2):161–172, 1982.
- M. Laguna. Scatter Search. P. M. Pardalos i M. G. C. Resende, red., *Handbook of Applied Optimization*, strony 183–193. Oxford University Press, 2002.
- M. Laguna i V. Armentano. Lessons from Applying and Experimenting with Scatter Search, 2003. Ukazuje się w Adaptive Memory and Evolution: Tabu Search and Scatter Search, C. Rego, B. Alidaee (red.).
- L. R. Lamberson i R. R. Hocking. Optimum time compression in project scheduling. *Management Science*, 16(10): B–597–B–606, 1970.
- J. K. Lee i Y. D. Kim. Search heuristics for resource constrained project scheduling. *Journal of Operational Research Society*, 47(5):678–689, 1996.
- V. J. Leon i R. Balakrishnan. Strength and adaptability of problem-space based neighborhoods for resource-constrained scheduling. *OR Spektrum*, 17:173–182, 1995.
- S. S. Leu i T. H. Hung. A genetic algorithm-based optimal resource-constrained scheduling simulation model. *Construction Management and Economics*, 20:131–141, 2002.
- S. S. Leu i C. H. Yang. GA-based multicriteria optimal model for construction scheduling. *Journal of Construction Engineering and Management*, 125(6):420–427, 1999.

- T. R. Levine i C. R. Hullett. Eta Squared, Partial Eta Squared, and Misreporting of Effect Size in Communication Research. *Human Communication Research*, 28(4):612–625, 2002.
- R. Y. Li i J. Willis. An iterative scheduling technique for resource-constrained project scheduling. *European Journal of Operational Research*, 56:370–379, 1992.
- H. W. Lilliefors. On the Kolmogorov-Smirnov test for normality with mean and variance unknown. *Journal of the American Statistical Association*, 64:399–402, 1967.
- N. R. Lofts. Multiple allocation of resources in a network – an optimal scheduling algorithm. *INFOR*, 12(1):25–38, 1974.
- A. Lova, C. Maroto i P. Tormos. A multicriteria heuristic method to improve resource allocation in multiproject scheduling. *European Journal of Operational Research*, 127:408–424, 2000.
- D. G. Luenberger. *Teoria inwestycji finansowych*. Polskie Wydawnictwo Naukowe, Warszawa, 2003.
- S. Mahfoud i G. Mani. Financial forecasting using genetic algorithms. *Journal of Applied Artificial Intelligence*, 10(6):543–565, 1996.
- G. Makarewicz i W. M. Zawieska. Zastosowanie algorytmów genetycznych do aktywnej redukcji hałasu. *Bezpieczeństwo pracy*, (1):4–6, 2003.
- A. Manikowski i Z. Tarapata. *Ocena projektów gospodarczych. Modele i metody*. Difin, Warszawa, 2001.
- C. Maroto i P. Tormos. Project Management: an Evaluation of Software Quality. *International Transactions in Operational Research*, 1(2):209–221, 1994.
- R. Martí, M. Laguna i V. Campos. Scatter Search Vs. Genetic Algorithms: An Experimental Evaluation with Permutation Problems, 2003a. Ukaże się w *Adaptive Memory and Evolution: Tabu Search and Scatter Search*, C. Rego, B. Alidaee (red.).
- R. Martí, M. Laguna i F. Glover. Principles of Scatter Search. Technical Report TR 07-2003, Universitat de Valencia, Dept. Estadística e Inv. Operativa, Spain, 2003b.
- A. T. Mason i C. L. Moodie. A branch and bound algorithm for minimizing cost in project scheduling. *Management Science*, 18(4):B–158–B–173, 1971.
- A. A. Mastor. An experimental and comparative evaluation of production line balancing techniques. *Management Science*, 16:728–746, 1970.
- D. C. Mattfeld. *Evolutinary Serach and the Job Shop: Investigations on Genetic Algorithms for Production Scheduling*. Physica/Springer Verlag, Heidelberg, 1995.
- H. Maylor. *Project Management*. Pearson Education, 3 edycja, 2003.
- C. Mellentien i N. Trautmann. Resource allocation with project management software. *OR Spektrum*, 23:383–394, 2001.
- D. Merkle i M. Middendorf. An ant algorithm with a new pheromone evaluation rule for total tardiness problems. *Proceeding of the EvoWorkshops 2000, Lecture Notes in Computer Science*, nr 1803, strony 287–296. Springer–Verlag, 2000.
- D. Merkle, M. Middendorf i H. Schmeck. Ant Colony Optimization for Resource-Constrained Project Scheduling. *Proceedings of the Genetic & Evolutionary Computation Conference (GECCO)*, strony 893–900, Las Vegas, 2000. Morgan Kaufmann.
- Z. Michalewicz. *Algorytmy genetyczne + struktury danych = programy ewolucyjne*. Wydawnictwa Naukowo–Techniczne, Warszawa, 1999.
- M. Mika, G. Waligóra i J. Węglarz. Simulated annealing and tabu search for multi-mode resource-constrained project scheduling with positive discounted cash flows and different payment models. *European Journal of Operational Research*, 164:639–668, 2005.
- A. Mingozzi, V. Maniezzo, S. Ricciardelli i L. Bianco. An exact algorithm for project scheduling with resources constraints based on a new mathematical formulation. *Management Science*, 44(5):714–729, 1998.
- R. P. Mohanty i M. K. Siddiq. Multiple projects-multiple resource-constrained scheduling: some studies. *International Journal of Production Research*, 27(2):261–280, 1989.
- R. H. Möhring. Minimizing Costs of Resource Requirements in Project Networks Subject to a Fixed Completion Time. *Operations Research*, 32(1):89–120, 1984.
- R. H. Möhring, A. S. Schulz, F. Stork i M. Uetz. Resource Constrained Project Scheduling: Computing Lower Bounds by Solving Minimum Cut Problems. Raport instytutowy 620/1998, Technische Universität Berlin, 1999. wersja poprawiona.
- M. Mori i C. C. Tseng. A genetic algorithm for multi-mode resource constrained project scheduling. *European Journal of Operational Research*, 100:134–141, 1997.

- I. Mukherjee i P. K. Ray. Optimal process design of two-stage multiple responses grinding processes using desirability functions and metaheuristic technique. *Applied Soft Computing*, 8(1):402–421, 2008.
- A. A. Najafi i S. T. A. Niaki. A genetic algorithm for resource investment problem with discounted cash flows. *Applied Mathematics and Computation*, 183:1057–1070, 2006.
- R. Nakano i T. Yamada. Conventional Genetic Algorithm for Job Shop Problems. R. K. Belew i L. B. Booker, red., *Proceedings of the Fourth International Conference on Genetic Algorithms*, San Mateo, California, 1991. Morgan Kaufmann.
- K. S. Naphade, S. D. Wu i R. H. Storer. Problem space search algorithms for resource-constrained project scheduling. *Annals of Operations Research*, 70:307–326, 1997.
- K. Neumann. Recent Developments in Stochastic Activity Networks. *INFOR*, 22(3):219–248, 1984.
- K. Neumann, H. Nübel i C. Schwindt. Active and stable project scheduling. *Mathematical Methods of Operations Research*, 52:441–465, 2000.
- K. Neumann i J. Zimmermann. Procedures for resource leveling and net present value problems in project scheduling with general temporal and resource constraints. *European Journal of Operational Research*, 127:425–443, 2000.
- B. A. Norman i J. C. Bean. Random Keys Genetic Algorithm for Scheduling. Raport instytutowy MI 48109, University of Michigan, Ann Arbor, 1995.
- B. A. Norman i J. C. Bean. Random keys genetic algorithm for complex scheduling problems. *Naval Research Logistics*, 46:199–211, 1999.
- B. A. Norman i J. C. Bean. Scheduling operations on parallel machine tools. *IIE Transactions*, 32:449–459, 2000.
- B. A. Norman i A. E. Smith. Random keys genetic algorithm with adaptive penalty function for optimization of constrained facility layout problems. *Proceedings of the IEEE Conference on Evolutionary Computing*, strony 407–411, Indianapolis, 1997.
- E. Nowak, E. Pielichaty i M. Poszwa. *Rachunek opłacalności inwestowania*. Polskie Wydawnictwo Ekonomiczne, Warszawa, 1999.
- E. Nowicki i C. Smutnicki. A fast taboo search algorithm for the job shop problem. *Management Science*, 42(6): 797–813, 1996.
- N. Nudtasomboon i S. Randhawa. Resource-constrained project scheduling with renewable and non-renewable resources and time-resource tradeoffs. *Computers & Industrial Engineering*, 32(1):227–242, 1997.
- S. Olejnik i J. Algina. Measures of Effect Size for Comparative Studies: Applications, Interpretations, and Limitations. *Contemporary Educational Psychology*, 25:241–286, 2000.
- E. Ostrowska. *Ryzyko projektów inwestycyjnych*. Polskie Wydawnictwo Ekonomiczne, Warszawa, 2002.
- L. Özdamar. A genetic algorithm approach to general category project scheduling problem. *IEEE Transactions on Systems, Man, and Cybernetics. Part C: Applications and Reviews*, 29:44–59, 1999.
- L. Özdamar i H. Dündar. A flexible heuristic for a multi-mode capital constrained project scheduling problem with probabilistic cash inflows. *Computers & Operations Research*, 24(12):1187–1200, 1997.
- L. Özdamar i G. Ulusoy. An iterative local constrained based analysis for solving the resource constrained project scheduling problem. *Journal of Operations Management*, 14(3):193–208, 1996a.
- L. Özdamar i G. Ulusoy. A note on an iterative forward/backward scheduling technique with reference to a procedure by Li and Willis. *European Journal of Operational Research*, 89:400–407, 1996b.
- L. Özdamar, G. Ulusoy i M. Bayyigit. A heuristic treatment of tardiness and net present value criteria in resource constrained project scheduling. *International Journal of Physical Distribution & Logistics Management*, 28(9–10): 805–824, 1998.
- R. Padman, D. E. Smith-Daniels i V. L. Smith-Daniels. Heuristic scheduling of resource-constrained projects with cash flows. *Naval Research Logistics*, 44(4):365–381, 1997.
- T. L. Pascoe. Allocation of resources – CPM. *Revue Française de Recherche Opérationnelle*, 38:31–38, 1966.
- J. H. Patterson. Project scheduling: The effects of problem structure on heuristic performance. *Naval Research Logistics*, 23:92–123, 1976.
- J. H. Patterson. A Comprasion of Exact Approaches for Solving Multiple Constrained Resource Project Scheduling Problem. *Management Science*, 30(7):854–867, 1984.
- J. H. Patterson i W. D. Huber. A Horizon-Varying, Zero-One Approach to Projecy Scheduling. *Management Science*, 20(6):990–998, 1974.
- J. H. Patterson, R. Słowiński, F. B. Talbot i J. Węglarz. Computational experience with a backtracking algorithm for solving a general class of precedence and resource-constrained scheduling problems. *European Journal of Operational Research*, 49:68–79, 1990.

- M. Pawlak. *Algorytmy ewolucyjne jako narzędzie harmonogramowania produkcji*. Wydawnictwo Naukowe PWN, Warszawa, 1999.
- J. S. Pennypacker i L. D. Dye, red. *Managing Multiple Projects*. PM Practices. Marcel Dekker, 2002.
- J. P. Pinder i A. S. Maruchek. Using discounted cash flow heuristics to improve project net present value. *Journal of Operations Management*, 14(3):229–240, 1996.
- E. Pinson, C. Prins i F. Rullier. Using tabu search for solving the Resource-Constrained Project Scheduling Problem. *International Workshop on Project Management and Scheduling, PMS'94*, strony 102–106, Louvain, Belgique, 1994.
- S. G. Ponnambalam, P. Aravindan i S. V. Rajesh. A Tabu Search Algorithm for Job Shop Scheduling. *International Journal of Advanced Manufacturing Technology*, 16:765–771, 2000.
- I. E. Premachandra. A Goal-programming Model for Activity Crashing in Project Networks. *International Journal of Operations & Production Management*, 13(6):79–85, 1993.
- A. A. B. Pritsker, L. J. Watters i P. M. Wolfe. Multiproject Scheduling with Limited Resources: A Zero-One Programming Approach. *Management Science*, 16(1):93–108, 1969.
- L. Raisanen i R. M. Whitaker. Comparison and Evaluation of Multiple Objective Genetic Algorithms for the Antenna Placement Problem. *Mobile Networks And Applications*, 10(1–2):79–88, 2005.
- M. R. Ranjbar i F. Kianfar. Solving the discrete time/resource trade-off problem project scheduling with genetic algorithms. *Applied Mathematics and Computation*, 191:451–456, 2007.
- J. P. Reddy, S. Kumanan i O. V. K. Chetty. Application of Petri Nets and a Genetic Algorithm to Multi-Mode Multi-Resource Constrained Project Scheduling. *International Journal of Advanced Manufacturing Technology*, 17:305–314, 2001.
- C. R. Reeves. Restricted neighbourhood search: an implicit tabu method. F. Glover, J. P. Kelly i I. H. Osman, red., *Proceedings of the 1st International Conference on Metaheuristics*, Denver, CO, 1995. University of Colorado.
- C. R. Reeves i T. Yamada. Genetic Algorithms, Path Relinking and the Flowshop Sequencing Problem. *Evolutionary Computation*, 6(1):230–234, 1998.
- B. De Reyck i W. Herroelen. On the use of the complexity index as a measure of complexity in activity networks. *European Journal of Operational Research*, 91:347–366, 1996.
- B. De Reyck i W. Herroelen. A branch-and-bound procedure for the resource-constrained project scheduling problem with generalized precedence relations. *European Journal of Operational Research*, 111:152–174, 1998.
- B. De Reyck i W. Herroelen. The multi-mode resource-constrained project scheduling problem with generalized precedence relations. *European Journal of Operational Research*, 119:538–556, 1999.
- W. Rogowski. *Rachunek efektywności przedsięwzięć inwestycyjnych*. Oficyna Ekonomiczna, Kraków, 2004.
- J. P. Royston. An extension of Shapiro and Wilk's W test for normality to large samples. *Applied Statistics*, 31: 115–124, 1982.
- A. H. Russell. Cash flows in networks. *Management Science*, 16(5):357–373, 1970.
- R. A. Russell. A comparison of heuristics for scheduling projects with cash flows and resource restrictions. *Management Science*, 32(10):1291–1300, 1986.
- F. Salewski, A. Schirmer i A. Drexler. Project Scheduling under Resource and Mode Identity Constraints. Part I: Model, Complexity Status, and Methods. Manuscript 387, Institut für Betriebswirtschaftslehre der Universität Kiel, 1996a.
- F. Salewski, A. Schirmer i A. Drexler. Project Scheduling under Resource and Mode Identity Constraints. Part II: An Application to Audit-Staff Scheduling. Manuscript 388, Institut für Betriebswirtschaftslehre der Universität Kiel, 1996b.
- F. Salewski, A. Schirmer i A. Drexler. Project scheduling under resource and mode identity constraints: Model, complexity, methods, and application. *European Journal of Operational Research*, 102:88–110, 1997.
- S. Sampson i E. Weiss. Local search techniques for the generalized resource-constrained project scheduling problem. *Naval Research Logistics*, 40:665–675, 1993.
- A. Schirmer. Advanced Biased Random Sampling in Serial and Parallel Scheduling, 1998. Niepublikowane.
- A. Schirmer. Adaptive control schemes applied to project scheduling with partially renewable resources. Manuscript 520, Institut für Betriebswirtschaftslehre der Universität Kiel, 1999.
- A. Schirmer. Case-Based Reasoning and Improved Adaptive Search for Project Scheduling. *Naval Research Logistics*, 47(3):201–222, 2000.
- A. Schirmer. Resource-constrained project scheduling: an evaluation of adaptive control schemes for parameterized sampling heuristics. *International Journal of Production Research*, 39(7):1343–1365, 2001.

- A. Schirmer i A. Drexl. Allocation of Partially Renewable Resources – Concept, Models and Applications. *Networks*, 37:21–34, 2001.
- A. Schirmer i S. Riesenberger. Parametrized Heuristics for Project Scheduling – Biased Random Sampling Methods. Manuskrypte 456, Institut für Betriebswirtschaftslehre der Universität Kiel, 1997.
- A. Schirmer i S. Riesenberger. Class-Based Control Schemes for Parameterized Project Scheduling Heuristics. Manuskrypte 471, Institut für Betriebswirtschaftslehre der Universität Kiel, 1998.
- C. Schwindt. ProGen/max: A New Problem Generator for Different Resource-Constrained Project Scheduling Problems with Minimal and Maximal Time Lags. Technical Report WIOR-449, Institut für Wirtschaftstheorie und Operations Research, Universität at Karlsruhe, 1995.
- C. Schwindt. Generation of Resource-Constrained Project Scheduling Problems Subject to Temporal Constraints. Technical Report WIOR-543, Institut für Wirtschaftstheorie und Operations Research, Universität at Karlsruhe, 1998.
- C. Schwindt i J. Zimmermann. A steepest ascent approach to maximizing the net present value of projects. *Mathematical Methods of Operations Research*, 53:435–450, 2001.
- A. B. Senouci i N. N. Eldin. Dynamic Programming Approach to Scheduling of Nonserial Linear Project. *Journal of Computing in Civil Engineering*, 10(2):106–114, 1996.
- S. Shadrokh i F. Kianfar. A genetic algorithm for resource investment project scheduling problem, tardiness permitted with penalty. *European Journal of Operational Research*, 181:86–101, 2007.
- M. Sierpińska i T. Jachna. *Ocena przedsiębiorstwa według standardów światowych*. Wydawnictwo Naukowe PWN, Warszawa, 1993.
- M. Sierpińska i D. Wędzki. *Zarządzanie płynnością finansową w przedsiębiorstwie*. Wydawnictwo Naukowe PWN, Warszawa, 2001.
- D. E. Smith-Daniels, R. Padman i V. L. Smith-Daniels. Heuristic scheduling of capital constrained projects. *Journal of Operations Management*, 14(3):241–254, 1996.
- A. Sprecher. Scheduling Resource-Constrained Projects Competitively at Modest Memory Requirements. *Management Science*, 46(5):710–723, 2000. Również: Manuskrypte aus den Institut für Betriebswirtschaftslehre der Universität Kiel, No. 425, November 1997.
- A. Sprecher i A. Drexl. Solving Multi-Mode Resource-Constrained Project Scheduling Problems by a Simple, General and Powerful Sequencing Algorithm. Part I: Theory. Manuskrypte 385, Institut für Betriebswirtschaftslehre der Universität Kiel, 1996a.
- A. Sprecher i A. Drexl. Solving Multi-Mode Resource-Constrained Project Scheduling Problems by a Simple, General and Powerful Sequencing Algorithm. Part II: Computation. Manuskrypte 386, Institut für Betriebswirtschaftslehre der Universität Kiel, 1996b.
- A. Sprecher i A. Drexl. Multi-mode resource-constrained project scheduling by a simple, general and powerful sequencing algorithm. *European Journal of Operational Research*, 107:431–450, 1998.
- A. Sprecher, S. Hartmann i A. Drexl. Project Scheduling with Discrete Time-Resource and Resource-Resource Tradeoffs. Manuskrypte 357, Institut für Betriebswirtschaftslehre der Universität Kiel, 1994.
- A. Sprecher, R. Kolisch i A. Drexl. Semi-active, active and non-delay schedules for the resource-constrained project scheduling problem. *European Journal of Operational Research*, 80:94–102, 1995.
- A. Stabryła. *Zarządzanie projektami ekonomicznymi i organizacyjnymi*. Wydawnictwo Naukowe PWN, Warszawa, 2006.
- J. P. Stinson. *A Branch and Bound Algorithm for a General Class of Resource-Constrained Scheduling Problems*. Praca doktorska, University of North Carolina, Chapel Hill, 1976.
- J. P. Stinson, E. W. Davis i B. M. Khumawala. Multiple Resource-Constrained Scheduling Using Branch and Bound. *AIIE Transactions*, 10(3):252–259, 1978.
- R. H. Storer, S. D. Wu i R. Vaccari. New search spaces for sequencing problems with application to job shop scheduling. *Management Science*, 38(10):1495–1509, 1992.
- R. H. Storer, S. D. Wu i R. Vaccari. Problem and Heuristic Space Search Strategies for Job Shop Scheduling. *ORSA Journal on Computing*, 7(4):453–487, 1995.
- F. Stork. Branch-And-Bound Algorithms For Stochastic Resource Constrained Project Scheduling. Raport instytutowy 702/2000, Technische Universität Berlin, 2000.
- F. Stork. *Stochastic Resource-Constrained Project Scheduling*. Praca doktorska, Technischen Universität Berlin, Berlin, 2001.
- F. Stork i M. Uetz. On the Representation of Resource Constraints in Project Scheduling. Raport instytutowy 693/2000, Technische Universität Berlin, 2001.

- T. Stützle i H. H. Hoos. MAX-MIN Ant System. *Future Generation Computer Systems*, 16(8):889–914, 2000.
- L. Sunde i S. Lichtenberg. Net-present-value cost/time tradeoff. *International Journal of Project Management*, 13(1):45–49, 1995.
- C. S. Sung i S. K. Lim. A scheduling procedure for a general class of resource constrained projects. *Computers & Industrial Engineering*, 32(1):9–17, 1997.
- G. Syswerda. *Schedule optimization Using Genetic Algorithms*, rozdział 21, strony 332–349. Van Nostrand Reinhold, New York, 1991.
- M. M. Sysło, N. Deo i J. S. Kowalik. *Algorytmy optymalizacji dyskretniej*. Wydawnictwo Naukowe PWN, Warszawa, 1995.
- M. Tagliasacchi. A genetic algorithm for optical flow estimation. *Image and Vision Computing*, 25(2):141–147, 2007.
- É. Taillard. Robust Taboo Search for Quadratic Assignment Problem. *Parallel Computing*, 17:443–455, 1991.
- F. B. Talbot. *An Integer Programming Algorithm for the Resource-Constrained Project Scheduling Problem*. Praca doktorska, Pennsylvania State University, 1976.
- F. B. Talbot. Resource-constrained project scheduling with time-resource trade offs: The nonpreemptive case. *Management Science*, 28(10):1197–1210, 1982.
- F. B. Talbot i J. H. Patterson. An efficient integer programming algorithm with network cuts for solving resource-constrained scheduling problems. *Management Science*, 24(11):1163–1174, 1978.
- L. Valadares Tavares. Multicriteria scheduling of a railway renewal program. *European Journal of Operational Research*, 25:395–405, 1986.
- L. Valadares Tavares, J. Antunes Ferreira i J. Silva Coelho. A comparative morphologic analysis of benchmark sets of project networks. *International Journal of Project Management*, 20(6):475–485, 2002.
- A. Thesen. Heuristic scheduling of activities under resource and precedence restrictions. *Management Science*, 23(4):412–422, 1976.
- A. Thesen. Measures of the restrictiveness of the project networks. *Networks*, 7:193–208, 1977.
- P. R. Thomas i S. Salhi. A Tabu Search Approach for the Resource Constrained Project Scheduling Problem. *Journal of Heuristics*, 4:123–139, 1998.
- H. Towarnicka. *Strategie inwestycyjne przedsiębiorstwa*. Wydawnictwo Akademii Ekonomicznej im. Oskara Langego we Wrocławiu, Wrocław, 2003.
- M. Trocki, B. Grucza i K. Ogonek. *Zarządzanie projektami*. Polskie Wydawnictwo Ekonomiczne, Warszawa, 2003.
- Y. W. Tsai i D. D. Gemmill. Using tabu search to schedule activities of stochastic resource-constrained projects. *European Journal of Operational Research*, 111:129–141, 1998.
- M. Uetz. *Algorithms for Deterministic and Stochastic Scheduling*. Praca doktorska, Technischen Universität Berlin, Berlin, 2001.
- G. Ulusoy i S. Cebelli. An equitable approach to the payment scheduling problem in project management. *European Journal of Operational Research*, 127:262–278, 2000.
- G. Ulusoy i L. Özdamar. A constraint-based perspective in resource constrained project scheduling. *International Journal of Production Research*, 32(3):693–705, 1994.
- G. Ulusoy i L. Özdamar. A heuristic scheduling algorithm for improving the duration and net present value of a project. *International Journal of Operations & Production Management*, 15(1):89–98, 1995.
- G. Ulusoy, F. Sivrikaya-Şerifoğlu i Ş. Şahin. Four Payment Models for the Multi-Mode Resource Constrained Project Scheduling Problem with Discounted Cash Flows. *Annals of Operations Research*, 102:237–261, 2001.
- R. J. M. Vaessens, E. H. L. Aarts i J. K. Lenstra. A local search template. *Computers & Operations Research*, 25(11):969–979, 1998.
- M. Vanhoucke, E. Demeulemeester i W. Herroelen. A New Random Network Generator For Activity-On-The-Node Network. *7th International Workshop on Project Management and Scheduling (PMS 2000)*, Osnabrück, Germany, 2000.
- M. Vanhoucke, E. Demeulemeester i W. Herroelen. Maximizing the net present value of a project with linear time-dependent cash flows. *International Journal of Production Research*, 39(14):3159–3181, 2001a.
- M. Vanhoucke, E. Demeulemeester i W. Herroelen. On Maximizing the Net Present Value of a Project Under Renewable Resource Constraints. *Management Science*, 47(8):1113–1121, 2001b.
- M. Vanhoucke, E. Demeulemeester i W. Herroelen. Discrete Time/Cost Trade-offs in Project Scheduling with Time-Switch Constraints. *Journal of Operational Research Society*, 53:1–11 (A), 2002a.

- M. Vanhoucke, E. Demeulemeester i W. Herroelen. Net Present Value Maximization of Projects with Progress Payments. Working Paper 2002/144, Ghent University, 2002b.
- M. G. A. Verhoeven. Tabu search for resource-constrained scheduling. *European Journal of Operational Research*, 106:266–276, 1998.
- A. Viana i J. P. de Sousa. Using metaheuristics in multiobjective resource constrained project scheduling. *European Journal of Operational Research*, 120:359–374, 2000.
- M. B. Wall. *A Genetic Algorithm for Resource-Constrained Scheduling*. Praca doktorska, Massachusetts Institute of Technology, 1996.
- B. L. Welch. On the comparison of several mean values: An alternative approach. *Biometrika*, 38:330–336, 1951.
- J. D. Wiest. Some properties of schedules for large projects with limited resources. *Operations Research*, 12(3): 395–418, 1964.
- J. D. Wiest. A heuristic model for scheduling large projects with limited resources. *Management Science*, 13(6): B–359–B–377, 1967.
- R. R. Wilcox. *Applying Contemporary Statistical Techniques*. Academic Press, 2002.
- M. Wirkus. *Zarządzanie przedsięwzięciami innowacyjnymi w dynamicznym środowisku wieloprojektowym*. Wydawnictwo Politechniki Gdańskiej, Gdańsk, 2006.
- K. J. Wróblewski i R. Krawczyński. *Zastosowanie reguł priorytetu w sterowaniu przepływem produkcji*. Prace naukowe PW – Organizacja i zarządzanie przemysłem z. 2. Wydawnictwa Politechniki Warszawskiej, Warszawa, 1985.
- J. Węglarz. Project scheduling with continuously-divisible, doubly-constrained resources. *Management Science*, 27 (9):1040–1053, 1981.
- T. Yamada i R. Nakano. A Genetic Algorithm Applicable to Large-Scale Job-Shop Problems. R. Männer i B. Manderick, red., *Parallel Problem Solving from Nature*, 2, Amsterdam, 1992. Elsevier Science Publishers, B. V.
- T. Yamada i R. Nakano. A Genetic Algorithm with Multi-Step Crossover for Job-Shop Scheduling Problems. *First IEE/IEEE International Conference on Genetic Algorithms in Engineering Systems: Innovations and Applications (GALESIA '95)*, strony 146–151, Sheffield, UK, 1995.
- T. Yamada i R. Nakano. *Job-Shop Scheduling by Simulated Annealing Combined with Deterministic Local Search*, strony 237–248. Kluwer Academic Publishers, 1996.
- T. Yamada i R. Nakano. Genetic Algorithms for Job-Shop Scheduling Problem. *Proceedings of Modern Heuristic for Decision Support*, London, 18–19 March, UNICOM Seminar, 1997.
- T. Yamada i C. R. Reeves. Permutation flowshop scheduling by genetic local search. *Proc. of the 2nd IEE/IEEE Int. Conf. on Genetic Algorithms in Engineering Systems (GALESIA '97)*, strony 232–238, 1997.
- T. Yamada i C. R. Reeves. Solving the C_{sum} Permutation Flowshop Scheduling Problem by Genetic Local Search. *IEEE International Conference on Evolutionary Computation*, strony 230–234, 1998.
- D. S. Yamashita, V. A. Armentano i M. Laguna. Scatter Search for Project Scheduling with Resource Availability Cost, 2003. Niepublikowane.
- K. K. Yang, L. C. Tay i C. C. Sum. A comparison of stochastic scheduling rules for maximizing project net present value. *European Journal of Operational Research*, 85:327–339, 1995.
- J. Yoo, T. Yang i J. P. Ignizio. An exchange heuristic for resource constrained scheduling with consideration given to opportunities for parallel processing. *Production Planning & Control*, 6(2):140–150, 1995.
- L. Zawadzka. *Metody ilościowe w organizacji i zarządzaniu. Część II*. Wydawnictwo Politechniki Gdańskiej, Gdańsk, 1997.
- H. Zhang, H. Li i C. M. Tam. Particle swarm optimization for resource-constrained project scheduling. *International Journal of Project Management*, 24:83–92, 2006a.
- H. Zhang, H. Li i C. M. Tam. Permutation-Based Particle Swarm Optimization for Resource-Constrained Project Scheduling. *Journal of Computing in Civil Engineering*, 20(2):141–149, 2006b.
- H. Zhang i C. M. Tam. Multimode Project Scheduling Based on Particle Swarm Optimization. *Computer-Aided Civil and Infrastructure Engineering*, 21:93–103, 2006.
- O. Zwikael, Y. Cohen i A. Sadeh. Non-delay scheduling as a managerial approach for managing projects. *International Journal of Project Management*, 24(4):330–336, 2006.